

# **XVIII Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA 2018)**

F. Herrera, S. Damas, R. Montes, S. Alonso  
A. González, Ó. Cordón, A. Troncoso, J. C. Riquelme,  
D. Camacho, P. A. González, M. J. del Jesus,  
S. Tabik, J. M. Juárez, A. Fernández, J. del Ser  
(Eds.)

October 23-26, 2018  
Granada, Spain



**XVIII Conferencia de la  
Asociación Española para  
la Inteligencia Artificial  
(CAEPIA 2018)**

*23-26 de octubre de 2018*

*Granada, España*

FRANCISCO HERRERA, SERGIO DAMAS

ROSANA MONTES, SERGIO ALONSO

ANTONIO GONZÁLEZ, ÓSCAR CORDÓN

ALICIA TRONCOSO, JOSÉ C. RIQUELME

DAVID CAMACHO, PEDRO ANTONIO GONZÁLEZ

MARÍA JOSÉ DEL JESUS, SIHAM TABIK

JOSÉ M. JUÁREZ, ALBERTO FERNÁNDEZ

JAVIER DEL SER





## Editores

### **Francisco Herrera**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

### **Sergio Damas**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

### **Rosana Montes**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

### **Sergio Alonso**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

### **Antonio González**

Departamento de Ciencias de la Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España

### **Óscar Cerdón**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

### **Alicia Troncoso**

Data Science & Big Data Lab  
University Pablo de Olavide  
Sevilla, España

### **José C. Riquelme**

Departamento de Lenguajes y Sistemas Informáticos  
Universidad de Sevilla  
Sevilla, España



**David Camacho**

Departamento de Ingeniería Informática  
Universidad Autónoma de Madrid  
Madrid, España

**Pedro Antonio González**

Departamento de Ingeniería del Software e Inteligencia Artificial  
Universidad Complutense de Madrid  
Granada, España

**María José del Jesus**

Departamento de Informática  
Universidad de Jaén  
Jaén, España

**Siham Tabik**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

**José Manuel Juárez**

Departamento de Ingeniería de la Información y las Comunicaciones  
Universidad de Murcia  
Murcia, España

**Alberto Fernández**

Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)  
Universidad de Granada  
Granada, España

**Javier del Ser**

TECNALIA  
University of the Basque Country  
Bilbao, España

**ISBN:** 978-84-09-05643-9

© F. Herrera et al. (Eds.), 2018

# Presentación CAEPIA 2018

En los últimos años la Inteligencia Artificial (IA) ha pasado de los laboratorios a estar entre nosotros, en nuestra vida cotidiana, con avances continuos en todos los ámbitos de nuestra sociedad (medicina, en el hogar, el software en los móviles, agricultura, ...). El impacto de la IA es transversal en todas las áreas, y asistimos a una continua presencia de la IA en los medios de comunicación que muestran su importancia e impacto creciente.

CAEPIA 2018 (XVIII Conferencia de la Asociación Española para la Inteligencia Artificial, Granada, 23-26 de Octubre de 2018) es el foro en el que la comunidad española presenta y discute sus últimos avances científicos y tecnológicos en IA. CAEPIA está abierta a la investigación formal, metodológica, técnica o aplicada, y se ha invitado a los investigadores a presentar sus logros más relevantes en cualquier área de la IA.

La serie de conferencias CAEPIA es un evento bienal que comenzó en 1985. Las ediciones anteriores se celebraron en Madrid, Alicante, Málaga, Murcia, Gijón, San Sebastián, Santiago de Compostela, Salamanca, Sevilla, La Laguna, Madrid, Albacete y Salamanca.

Dentro de CAEPIA, junto con las sesiones generales, se celebran diversos congresos y talleres federados: XIX Congreso Español Sobre Tecnologías y Lógica Fuzzy (ESTYLF), XIII Congreso Español de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB), IX Simposio de Teoría y Aplicaciones de la Minería de Datos (TAMIDA), V Congreso de la Sociedad Española para las Ciencias del Videojuego (CoSECiVi), IV Jornadas de Fusión de la Información y Ensemble Learning (IV FINO), II Workshop en Big Data y Análisis de Datos Escalable (II BigDADE), I Workshop en Ciencia de Datos en Redes Sociales (CiDReS), I Workshop en Deep Learning (DeepL 2018), I Workshop de Grupos de Investigación Españoles de IA en Biomedicina (IABiomed 2018), y I Workshop en Aplicaciones de la Inteligencia Artificial para la Industria 4.0 (Industria 4.0 2018). También se organiza el Doctoral Consortium (DC), un foro para que estudiantes de doctorado pudieran interactuar con otros investigadores discutiendo sobre sus avances y planes de tesis.

Con el fin de subrayar la importancia práctica de la IA a nivel de aplicaciones móviles, en CAEPIA 2018 tiene lugar la 3ª Competición de Apps con técnicas de IA. También hay una ventana a la divulgación con la Competición de Vídeos Divulgativos de IA.

Además de la presentación de contribuciones completas y del DC, el programa científico de CAEPIA 2018 incluyó una llamada a la presentación de artículos relevantes recientes (Key Works, KW) ya publicados en revistas y foros de reconocido prestigio.

CAEPIA tiene como objetivo ser reconocida como una de los congresos de referencia en IA, manteniendo los estándares de alta calidad de ediciones previas. Una selección de los trabajos aceptados se ha publicado en un volumen especial de la serie “Lecture Notes in Artificial Intelligence” de Springer con 36 trabajos (LNAI, volume 11160). Junto a ese volumen, está el presente libro con aproximadamente 1500 páginas y poco más de 200 trabajos, junto con los trabajos del DC y competiciones. Esto implicó un gran trabajo del Comité de Programa de CAEPIA 2018 y congresos asociados que los organizadores



agradecen enormemente.

AEPIA y la organización de CAEPIA 2018 reconocerán los mejores trabajos y propuestas de tesis doctoral del DC. Como en anteriores ediciones, el premio Frances Allen reconocerá a las dos mejores tesis doctorales en IA defendidas por investigadoras durante los dos últimos años.

CAEPIA 2018 ha invitado a cinco investigadores de reconocido prestigio para impartir conferencias plenarias invitadas: Pedro Larrañaga (Universidad Politécnica de Madrid, España) presenta “Redes Bayesianas en Acción”. Sergio Guadarrama (Google AI - USA) introduce “IA en Google: últimos avances y tendencias”. Carlos Coello (CINVESTAD-IPN, México) se centra en “Tendencias en la Investigación en Optimización Evolutiva Multiobjetivo”. Joao Gamma (Universidad de Oporto, Portugal), presenta “Minería de Datos en Tiempo Real”, y finalmente, Humberto Bustince (Universidad Pública de Navarra, España) presenta “De Integrales a Pre-agregaciones: Aplicaciones en Clasificación, el Cerebro Computacional y el Procesamiento de Imágenes”.

El jueves día 25 de octubre, se organiza una Mesa Redonda, “Inteligencia Artificial y Sociedad”, donde se analizará la presencia de la Inteligencia Artificial en todos los ámbitos de nuestra sociedad, el presente y futuro desde una perspectiva transversal. Participarán expertos del mundo académico, de la empresa, e institucional que nos hablarán sobre la situación actual de la IA, la agenda estratégica, aplicación en la industria, los aspectos éticos de la IA y el impacto futuro en nuestra sociedad.

Agradecemos el trabajo de todos los que contribuyeron al éxito de CAEPIA 2018: autores, miembros de los Comités Científicos y de Programa, nuestros patrocinadores locales (“Instituto de Investigación Andaluz en Data Science and Computational Intelligence - DaSCI” y la Universidad de Granada), el equipo de Springer, nuestros sponsors (Repsol y Zio) y la asociación AEPIA por su soporte.

Aprovechamos estas líneas para desear a todos los asistentes que disfruten del congreso, del interesante debate científico y de las actividades organizadas para estos días.

Francisco Herrera (Presidente General de CAEPIA 2018) y Sergio Damas (Presidente del Comité Organizador CAEPIA 2018) en nombre de los participantes de CAEPIA 2018 queremos agradecer especialmente al Prof. Enric Trillas (Presidente de Honor de CAEPIA 2018) por su trabajo pionero en IA, sus numerosas iniciativas para promocionar la IA en España y su amistad.

Octubre 2018

Francisco Herrera  
Sergio Damas  
Universidad de Granada

# Presentación de la Presidenta de la Asociación Española para la Inteligencia Artificial

Como Presidenta de la Asociación Española para la Inteligencia Artificial es para mí un gran placer presentaros esta nueva edición en Granada de la serie de conferencias CAEPIA. Estas conferencias comenzaron a celebrarse a mediados de los años 80, cuando un grupo de investigadores españoles, visionarios y pioneros en una disciplina que se llamaba Inteligencia Artificial, decidieron unir sus esfuerzos, fundaron AEPIA e iniciaron esta serie de conferencias bianuales. Echando la vista atrás, no podemos más que alegrarnos de esa temprana visión, continuada por los esfuerzos que muchos investigadores han realizado durante todos estos años para que el campo creciese continuamente, promoviendo la investigación en Inteligencia Artificial en las diversas áreas de la disciplina, presentes en los diferentes workshops, sesiones especiales, tutoriales, etc. incluidos en esta XVIII CAEPIA. La conferencia incluye también programas para los estudiantes y los jóvenes investigadores, como es el caso del Doctoral Consortium o los Premios a los Jóvenes investigadores autores de los mejores artículos. En AEPIA también contribuimos con acciones de género positivas mediante los premios Frances Allen a las mejores tesis doctorales realizadas por mujeres, en un intento de reducir la brecha de género e incorporar más talento a la disciplina. El pasado, el presente y el futuro se incuban, se dan la mano y se apoyan en todos los eventos de CAEPIA.

Aquellos años 80 de nuestros pioneros en IA y este evento del 2018 comparten algo en común, más allá del esfuerzo entusiasta de los investigadores en el área: en ambas épocas la Inteligencia Artificial estaba en un momento álgido. En los años 80 estábamos en un período que se suele denominar “período industrial”, en el que la disciplina florecía de la mano del uso de conocimiento especializado de alto nivel dentro de los programas. En la actualidad, la industria ha abrazado a la Inteligencia Artificial como una de las áreas más importantes para el cambio que se está produciendo y que nos lleva a la Industria y la Sociedad 4.0. La IA irrumpió con fuerza en la industria en los años 2011-12, coincidiendo irónicamente estos años con la muerte de dos de los investigadores internacionales pioneros de esta disciplina, John McCarthy y Marvin Minsky. Este resurgimiento de la Inteligencia Artificial se debe a varios motivos, ya que en varias de las tecnologías fundacionales surgieron cambios importantes que contribuyeron a crear el caldo de cultivo adecuado. La mayoría de estos cambios están relacionados con la disponibilidad tanto de grandes cantidades de datos, como de la infraestructura y las herramientas necesarias para procesarlos de manera rápida y barata. Hoy en día, muchas de las ideas y posibilidades que soñaron los fundadores de la IA se han hecho posibles, y nuestra disciplina está en consecuencia más viva que nunca.

En nuestro país estamos en la actualidad en una encrucijada, con unas expectativas muy altas en nuestra futura agenda estratégica que indudablemente estará muy influida por las políticas de la Unión Europea (UE), y la agenda estratégica que está diseñando la Comisión Europea (CE) y que verá la luz en unos meses. La CE ha creado foros donde confluyen investigadores, inversores y empresarios, como



la Alianza Europea de IA, que fomenta discusiones amplias y abiertas sobre todos los aspectos del desarrollo de la Inteligencia Artificial, y su impacto en la economía y la sociedad. La CE ha creado también un Grupo de Expertos de Alto Nivel en IA, que se está encargando de elaborar las líneas directrices en ética y explicabilidad, de recoger las áreas de trabajo relevantes para la UE, así como otros informes que deben contribuir a situar a las naciones europeas en el mapa de la IA mundial, un mapa en el que China y los Estados Unidos ostentan las primeras posiciones en inversión económica. Pero, aunque esto es importante e ineludible, ninguno de esos dos países tiene el monopolio del talento. En cualquier caso, debemos estar atentos a las inversiones, que son las que atraen este talento. El Instituto Tecnológico de Massachusetts, MIT, una de las cunas de la IA, acaba de anunciar un nuevo plan para reformar su programa académico alrededor de la tecnología, creará un nuevo “college” que combine IA, aprendizaje automático y ciencia de datos, junto con otras disciplinas, e invertirá 1 billón de dólares. En Europa, el plan francés prevé una inversión similar, de unos 1.500 millones de euros, repartida en los próximos cinco años, para el desarrollo de una inteligencia artificial francesa y europea, en la que prevé entre otros temas la recuperación de talento que emigró a otros países, además del fomento de nuevas vocaciones en Inteligencia Artificial. Recientemente, ha anunciado una nueva inversión de 10 millones de euros más, dedicada a ayudas para startups. En España sin embargo, el presupuesto de investigación en Inteligencia Artificial para tres años ronda los 8 millones de euros. Siguiendo los pasos del camino que ha iniciado Francia con su plan nacional “Inteligencia Artificial para la Humanidad”, la Unión Europea y España como parte integrante de ella, deben estar presentes para poder diseñar el futuro. Para ello, es necesario contar con un plan estratégico y un plan inversiones mucho más ambicioso.

La Inteligencia Artificial es ahora mismo una de las tecnologías que más impacto está causando en nuestra vida como individuos y como sociedades. Durante los próximos años asistiremos a un crecimiento continuo de la IA tanto en sofisticación como en objetivos, y muy probablemente a una inversión creciente de la industria. Todos nosotros tenemos la responsabilidad y el reto de trabajar en esta excitante área.

Amparo Alonso Betanzos  
Presidenta de AEPIA

# Ponentes Plenarios

## **Pedro Larrañaga**, Universidad Politécnica de Madrid

Pedro Larrañaga es Catedrático de Ciencias de la Computación e Inteligencia Artificial en la Universidad Politécnica de Madrid (UPM) desde 2007, donde codirige el Grupo de Inteligencia Computacional. Es licenciado en Matemáticas (Estadística) por la Universidad de Valladolid y doctor en Informática por la Universidad del País Vasco (premio a la excelencia). Antes de incorporarse a la UPM, su trayectoria académica se desarrolló en la Universidad del País Vasco (UPV-EHU) en diversos puestos: Profesor Ayudante (1985-1998), Profesor Asociado (1998-2004) y Profesor Titular (2004-2007). Obtuvo la habilitación para Catedrático en 2003.



El profesor Larrañaga ha sido responsable del Plan Nacional en el área de Informática dentro de la Subdirección General de Proyectos de Investigación del Ministerio de Ciencia e Innovación (2007-2010). Asimismo, ha sido miembro del Comité Asesor 6.2 (Ingeniería de Comunicaciones, Informática y Electrónica) de la CNEAI (Ministerio de Educación) en el periodo 2010-2011.

Sus intereses de investigación se centran principalmente en las áreas de modelos gráficos probabilísticos, ciencia de datos, metaheurística y aplicaciones reales, en áreas tales como: biomedicina, bioinformática, neurociencia, industria 4.0 y deportes. Ha publicado más de 200 artículos en revistas con factor de impacto y ha supervisado 25 tesis doctorales. Es miembro electo de la Asociación Europea de Inteligencia Artificial desde 2012 y de la Academia Europaea desde 2018. Ha sido galardonado con el *Premio Nacional de Informática 2013* y con el *Premio de la Asociación Española de Inteligencia Artificial 2018*.

## **Redes Bayesianas en Acción**

En la ponencia se presentará el uso de las redes Bayesianas en aplicaciones recientes en tres áreas diferentes: neurociencia, industria4.0 y analítica deportiva.

Las aplicaciones en neurociencia tratarán problemas a diferentes escalas: desde cuestiones de neuroanatomía, como la clasificación interneuronal y el clustering de espinas, hasta el diagnóstico de enfermedades neurodegenerativas como el Parkinson y el Alzheimer. Las aplicaciones en la Industria 4.0 estarán relacionadas con la inspección automática de un proceso láser y el descubrimiento de huellas dactilares en una máquina que trabaja con servomotores. Finalmente, soluciones al problema de la predicción del rendimiento de jugadores de fútbol profesional, y el abordaje del fútbol como ciencia ilustrarán la analítica deportiva.



Desde el punto de vista del aprendizaje automático, se utilizarán varias técnicas, como el cluster probabilístico, el clustering multivista, la detección de anomalías, la clasificación supervisada, la clasificación multietiqueta y la regresión con varias variables a predecir, todo ello en escenarios estáticos y dinámicos. Estas técnicas constituyen el fundamento de los métodos usados en las aplicaciones anteriores.

## **Sergio Guadarrama, Senior SWE, Google AI**

El Dr. Sergio Guadarrama es Ingeniero Senior de Software en Google Research, donde trabaja en Machine Perception y Deep Learning como miembro del equipo VALE con el Dr. Kevin Murphy. Su foco de investigación está en la búsqueda de nuevas arquitecturas de redes neuronales para predicciones detalladas de múltiples tareas, como la detección de objetos, la segmentación de objetos, la predicción de color y la respuesta a preguntas basadas en imágenes. Actualmente es desarrollador de TensorFlow y co-creador de TensorFlow-Slim. Antes de unirse a Google, fue investigador científico de la Universidad de California en Berkeley EECS con el prof. Trevor Darrell y el prof. Lotfi Zadeh. En UC-Berkeley fue uno de los desarrolladores de Caffe: Convolutional Architecture for Fast Feature Embedding. Recibió su licenciatura y su doctorado en la Universidad Politécnica de Madrid, e hizo un postdoctorado en el Centro Europeo de Soft Computing con el Prof. Enric Trillas.



El Dr. Guadarrama ha publicado más de 60 artículos en conferencias internacionales de primer nivel (CVPR, NIPS, AAI, ICCV, RSS, ICRA, IROS, ACM, BMVC,...) y revistas sobre Inteligencia Artificial y Visión por Ordenador, que desde entonces han obtenido más de 10000 citas.

Las investigaciones y contribuciones originales del Dr. Guadarrama al campo le han valido los siguientes premios: el Everingham Prize 2017 al equipo de Caffe: Convolutional Architecture for Fast Feature Embedding por su contribución a la comunidad de código abierto, fue parte del equipo ganador del COCO 2016 Detection Challenge, ganador de la ACM Multimedia Open-Source Software Competition in 2014, la Beca de Movilidad para Investigación Postdoctoral del Ministerio de Ciencia e Innovación Español, el Premio “Juan de la Cierva” en Informática del Ministerio Ciencia e Innovación de Español, y el Premio a la Mejor Tesis Doctoral de 2006-2007 por la Universidad Politécnica de Madrid (director: Prof. Enric Trillas).

## **Inteligencia Artificial en Google: últimos avances y tendencias**

Over last few years, Artificial Intelligence (AI) has seen huge growth, mainly due to the raise of Deep Learning and its impressive results on long standing AI research fields as speech understanding, natural language processing, computer vision, or in robotics.

Some specific problems successfully tackled include: Machine Translation, Speech Understanding and Generation, Object Detection, Semantic Segmentation and Pose Estimation, Deep Reinforcement Learning for Robotic Manipulation and Self-Supervised Learning.

The growth of Deep Learning has been driven by improvements in hardware (GPUs, TPUs, etc.) and by improvements in software (Caffe, TensorFlow, PyTorch, etc.), but also by improvements in models (Convolutional Nets, Residual Nets, Recurrent Nets, Generative Adversarial Nets, etc.).



Neural networks have proven effective at solving difficult problems but designing their architectures can be challenging, even for a specific type of problems alone (as image classification). Reinforcement Learning and Evolutionary algorithms provide techniques to discover such networks automatically, recently there has been a lot of development in AutoML.

Finally there is a big potential of applying Machine Learning to help solve important problems in different fields of science. For example, last year researchers utilized neural networks and deep learning for predicting molecular properties in quantum chemistry, finding new exoplanets in astronomical datasets, predicting earthquake aftershock, guiding automated proof systems.

## **Carlos A. Coello Coello, CINVESTAV-IPN, México**

Carlos Artemio Coello Coello cursó estudios en ingeniería civil en la Universidad Autónoma de Chiapas graduándose con mención honorífica en 1991. Ese mismo año, recibió la Medalla Diario de México por ser uno de los mejores estudiantes de México. Posteriormente, obtuvo una beca de la Secretaría de Educación Pública de México para cursar estudios de maestría y doctorado en ciencias de la computación en la Universidad Tulane, en Estados Unidos, graduándose en 1993 y 1996, respectivamente. Desde 2001, es Investigador Titular en el Departamento de Computación del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV-IPN) en la Ciudad de México.



El Dr. Coello ha sido pionero en un área que hoy se conoce como optimización evolutiva multi-objetivo, la cual se enfoca a la solución de problemas de optimización con dos o más funciones objetivo (normalmente en conflicto entre sí) usando algoritmos con inspiración biológica. Su trabajo ha girado principalmente en torno al diseño de algoritmos, varios de los cuales han sido utilizados para resolver problemas de mundo real en Estados Unidos, Colombia, Chile, Japón, Irán, Cuba y México.

El Dr. Coello cuenta con más de 450 publicaciones (incluyendo 1 libro monográfico en inglés, más de 140 artículos en revistas con arbitraje estricto y 55 capítulos en libros en inglés), las cuales reportan a la fecha más de 40,000 citas en Google Scholar (su índice h es de 78). Es también editor asociado de varias revistas internacionales, incluyendo las 2 más importantes de su área (IEEE Transactions on Evolutionary Computation y Evolutionary Computation). También es miembro del Consejo Asesor de la Natural Computing Book Series de Springer.

A lo largo de su carrera ha recibido diversos premios, de entre los que destacan el Premio Nacional de Investigación 2007 en “ciencias exactas” de la Academia Mexicana de Ciencias, la Medalla al Mérito Científico 2009 de parte de la Asamblea Legislativa del Distrito Federal, el Premio Scopus México 2012 en Ingeniería, el Premio Ciudad Capital: Heberto Castillo Martínez–Edición 2011, en Ciencias Básicas y el Premio Nacional de Ciencias y Artes 2012, en el área de Ciencias Físico-Matemáticas y Naturales. Este último es el premio más importante que otorga el gobierno mexicano a un científico. Desde enero de 2011 es IEEE Fellow por sus “contribuciones a la optimización mono-objetivo y multi-objetivo usando metaheurísticas”. También recibió el 2013 IEEE Kiyo Tomiyasu Award por “contribuciones pioneras a la optimización mono- y multi-objetivo usando metaheurísticas bio-inspiradas” y en noviembre de este año recibirá el 2016 The World Academy of Sciences (TWAS) Award en “Engineering Sciences” por “contribuciones pioneras al desarrollo de nuevos algoritmos basados en metaheurísticas bio-inspiradas para resolver problemas de optimización mono-objetivo y multi-objetivo”.



## ¿Hacia dónde va la investigación en optimización evolutiva multi-objetivo?

El primer algoritmo evolutivo multi-objetivo se publicó en 1985. Sin embargo, fue hasta a finales de los 1990s cuando la denominada optimización evolutiva multi-objetivo comenzó a ganar popularidad como área de investigación. A lo largo de estos 33 años, se han producido diferentes avances muy importantes en el área, incluyendo el desarrollo de diferentes familias de algoritmos, problemas de prueba, indicadores de desempeño, métodos híbridos y aplicaciones del mundo real, entre muchos otros. En la primera parte de esta plática se dará un vistazo rápido a algunos de estos avances, enfatizando principalmente los logros recientes más importantes. En la segunda parte de la plática, se hará un análisis crítico sobre la investigación por analogía que ha proliferado en años recientes en las revistas y congresos especializados (tal vez como un efecto colateral de la abundancia de publicaciones que ha experimentado esta área). Mucha de esta investigación cuenta con un nivel muy bajo de innovación y con un aporte casi nulo en términos científicos, pero va respaldado por un gran número de tablas y análisis estadísticos. En la tercera y última parte de la plática, se mencionarán brevemente algunos de los retos de investigación futuros para esta área que, tras 33 años de existencia, apenas comienza su etapa de madurez.

### **João Gama, Universidad de Porto, Portugal**

João Gama es Profesor Asociado de la Universidad de Oporto, Portugal. También es investigador senior y miembro de la junta directiva del Laboratorio de Inteligencia Artificial y Soporte a la Decisión (LIAAD), grupo perteneciente al INESC Porto.

João Gama es miembro del Consejo Editorial de Machine Learning Journal, Data Mining and Knowledge Discovery, Intelligent Data Analysis y New Generation Computing. Fue Copresidente de ECML 2005, DS09, ADMA09 y de una serie de Talleres sobre KDDs y Descubrimiento de Conocimientos a partir de Datos de Sensores con ACM SIGKDD. También fue presidente de la conferencia Intelligent Data Analysis 2011. Su principal interés en la investigación es el descubrimiento de conocimiento a partir de flujos de datos y datos en evolución. Es autor de más de 200 artículos revisados por colegas y autor de un libro reciente sobre Descubrimiento de Conocimientos de Data Streams. Tiene extensas publicaciones en el área de aprendizaje de flujos de datos.



### **Real-Time Data Mining**

Hoy en día, hay aplicaciones en las que los datos se modelan mejor no como tablas persistentes, sino como flujos de datos transitorios. En esta nota clave, discutimos las limitaciones del aprendizaje de la máquina actual y los algoritmos de minería de datos. Discutimos los temas fundamentales del aprendizaje en entornos dinámicos como los modelos de decisión de aprendizaje que evolucionan con el tiempo, el aprendizaje y el olvido, la deriva conceptual y la detección de cambios. Los flujos de datos se caracterizan por una gran cantidad de datos que introducen nuevas restricciones en el diseño de los algoritmos de aprendizaje: recursos computacionales limitados en términos de memoria, tiempo de procesamiento y potencia de la CPU. En esta charla, presentamos algunos algoritmos ilustrativos diseñados para tomar en cuenta estas restricciones. Identificamos los principales problemas y desafíos



actuales que surgen al aprender de los flujos de datos, y presentamos líneas de investigación abiertas para futuros desarrollos.

## **Humberto Bustince, Universidad Pública de Navarra**

Humberto Bustince es catedrático de Ciencia de la Computación e Inteligencia Artificial de la Universidad Pública de Navarra y profesor honorario de la Universidad de Nottingham. Es el investigador principal del Grupo de Inteligencia Artificial y Razonamiento Aproximado de la Universidad Pública de Navarra, y sus principales líneas de investigación son tanto teóricas (funciones de agregación y pre-agregación, medidas de información y comparación, conjuntos difusos y sus extensiones) como aplicadas (procesamiento de imagen, clasificación, machine learning, minería de datos, big data y Deep learning). Ha sido responsable de 11 proyectos de investigación con financiación pública tanto a nivel nacional como regional. También ha sido el responsable de proyectos de colaboración con empresas de primer orden en banca, energía renovables o seguridad, entre otros campos. Ha tomado parte en dos proyectos de investigación internacionales.



Es co-autor de más de 240 trabajos de acuerdo con Web of Science, la mayor parte de ellos en revistas del primer cuartil del JCR. Además, seis de estos trabajos están entre los artículos altamente citados de los últimos 10 años, de acuerdo con Science Essential Indicators de Web of Science. Es editor en jefe del magazine online Mathware&Soft Computing de la asociación europea EUSFLAT y de la revista Axioms. También es editor asociado de la revista IEEE Transactions on Fuzzy Systems, y miembro del Comité Editorial de las revistas FuzzySets and Systems, Information Fusion, International Journal of Computational Intelligence Systems y Journal of Intelligent & Fuzzy Systems.

Es miembro Senior de la asociación IEEE y Fellow de IFSA. En 2015 recibió el premio al mejor trabajo publicado en la revista IEEE Transactions on Fuzzy Systems en el año 2013, y en 2017 fue galardonado con la Cruz de Carlos III el Noble del Gobierno de Navarra.

## **Pre-agregaciones a partir de integrales y sus aplicaciones en clasificación, el cerebro computacional y procesamiento de imagen**

A partir de los últimos estudios en Deep Learning y Big-data, se observa que existe un creciente interés en desarrollar nuevos métodos para fusionar información. Estos métodos, aunque no son agregaciones en el sentido usual ya que no se modelizan utilizando funciones monótonas, sí que presentan un elevado valor por su aplicación en cualquier disciplina en la que la fusión de datos sea un elemento relevante. Un paso muy importante en esta dirección ha sido la introducción del concepto pre-agregación, que es una función que satisface las mismas condiciones de contorno que una función de agregación, pero que es creciente a lo largo de solo una dirección. En esta charla, veremos ejemplos de cómo pueden construirse estas funciones por medio de generalizaciones de las integrales de Choquet y Sugeno. También veremos cómo estas generalizaciones pueden utilizarse para construir detectores de bordes que proporcionan excelentes resultados, o sistemas de clasificación que igualan e incluso mejoran el estado del arte. En particular, discutiremos la aplicaciones de estas pre-agregaciones en el estudio del cerebro computacional para la clasificación de señales.



# Organización

## Presidente de Honor

Enric Trillas

Universidad de Oviedo, España

## Presidente General

Francisco Herrera

Universidad de Granada, España

## Presidente del Comité de Organización

Sergio Damas

Universidad de Granada, España

## Presidente del Comité de Premios

Enrique Alba

Universidad de Málaga, España

## Presidente de los Tutoriales y Talleres

Luís Martínez

Universidad de Jaén, España

## Presidentes de las Conferencias y Talleres Federados

### ESTYLF 2018

Antonio González

Universidad de Granada, España

Enrique Herrera-Viedma

Universidad de Granada, España

### MAEB 2018

Oscar Cordón

Universidad de Granada, España

Rafael Martí

Universidad de Valencia, España



## **TAMIDA 2018**

José Riquelme  
Alicia Troncoso  
Salvador García

University of Sevilla, España  
Universidad Pablo de Olavide, España  
Universidad de Granada Spain

## **CiDReS 2018**

David Camacho  
Victoria Luzón

Universidad Autónoma de Madrid, España  
Universidad de Granada, España

## **CoSECiVi 2018**

Pedro Antonio González  
David Camacho

Universidad Complutense de Madrid, España  
Universidad Autónoma de Madrid, España

## **BigDADE 2018**

Amparo Alonso  
Maria José del Jesus  
Francisco Herrera

University of Coruña, España  
Universidad de Jaén, España  
Universidad de Granada, España

## **DEEPL 2018**

Siham Tabik  
Antonio Bahamonde  
Juan Manuel Górriz

Universidad de Granada, España  
Universidad de Oviedo, España  
Universidad de Granada, España

## **IABiomed 2018**

José M. Juarez  
Mar Marcos  
David Riaño

Universidad de Murcia, España  
Universitat Jaume I, España  
Universitat Rovira i Virgili, España

## **FINO 2018**

Emilio Corchado  
Mikel Galar  
Bruno Baruque  
Alberto Fernández

Universidad de Salamanca, España  
Universidad Pública de Navarra, España  
Universidad de Burgos, España  
Universidad de Granada, España

## **IndustrIA 4.0**

Javier Del Ser  
José Antonio Lozano

TECNALIA, Universidad del País Vasco, España  
Universidad del País Vasco, España

## **Doctoral Consortium**

José Riquelme  
Humberto Bustince

Universidad de Sevilla, España  
Universidad Pública de Navarra, España



## Competición de Apps

Alberto Bugarín  
José Antonio Gámez

Universidad de Santiago de Compostela, España  
Universidad de Castilla la Mancha, España

## Competición de Vídeos

José Antonio Gámez  
Alberto Bugarín

Universidad de Castilla la Mancha, España  
Universidad de Santiago de Compostela, España

## Comité de Organización

- **Secretario:** Pedro Villar
- **Publicación y Programa:** Sergio Alonso, Jorge Casillas y Julián Luengo
- **Publicidad:** M. Dolores Pérez y Pedro González
- **Logotipo:** Manuel Parra
- **Web:** Rosana Montes
- **Secretarías Técnicas**
  - **ESTYLF:** Raul Pérez y Javier Cabrerizo
  - **MAEB:** Daniel Molina y Maria Isabel García
  - **CoSECiVi:** Marco Antonio Gómez y Antonio Mora
  - **CiDReS:** Eugenio Martínez
- **Jurado Competición de Apps:** Alberto J. Bugarín (Presidente), Bertha Guijarro, Eva Onaindia, Alicia Troncoso y Óscar Luaces
- **Jurado Competición de Vídeos:** Senén Barro Ameneiro (Presidente), Juan Manuel Corchado, Óscar Cordón, María José del Jesus y José A. Gámez

## Presidentes de las Áreas

### Incertidumbre en I.A.

Pedro Larrañaga Múgica

Univesidad Politécnica de Madrid, España

### Procesamiento del Lenguaje Natural

Patricio Martínez Barco

Universidad de Alicante, España



## **Representación del Conocimiento, Razonamiento y Lógica**

Pedro Meseguer González      IIIA-CSIC, España

## **Restricciones, Búsqueda y Planificación**

Eva Onaindia De La Rivaherrera      Universidad Politécnica de Valencia, España

## **Sistemas Multi-Agente**

Juan Pavón Mestras      Universidad Complutense de Madrid, España

## **Web Inteligente y Recuperación de la Información**

Juan Manuel Fernández Luna      Universidad de Granada, España

## **Visión por Computador y Robótica**

Petia Radeva      Universidad de Barcelona, España

## **Datos Abiertos y Ontologías**

Asunción Gómez Perez      Universidad Politécnica de Madrid, España

## **Inteligencia Ambiental y Entornos Inteligentes**

Jesús García Herrero      Universidad Carlos III de Madrid, España

## **Creatividad e Inteligencia Artificial**

Miguel Molina Solana      Imperial College London, Reino Unido

## **Fundamentos, Modelos y Aplicaciones de la I.A.**

Serafín Moral Callejón      Universidad de Granada, España

## **Comité de Programa**

### **CAEPIA 2018**

Jesús S. Aguilar-Ruiz	Universidad Pablo de Olavide
Enrique Alba	Universidad de Málaga
Amparo Alonso-Betanzos	Universidad de A Coruña
Martín Álvarez	Consortio W3C
Lourdes Araujo	Universidad Nacional de Educación a Distancia



Jaume Bacardit	Universidad de Newcastle
Antonio Bahamonde	Universidad de Oviedo en Gijon
Javier Bajo	Universidad Politécnica de Madrid
Ana M. Barbancho	Universidad de Malaga
Alvaro Barreiro	Universidad de A Coruña
Eduarne Barrenechea	Universidad Pública de Navarra
Senén Barro	Universidad de Santiago de Compostela
José Ángel Bañares	Universidad de Zaragoza
Antonio Berlanga	Universidad Carlos III de Madrid
Ana M. Bernardos	Universidad Politécnica de Madrid
Concha Bielza Lozoya	Universidad Politécnica de Madrid
Daniel Borrajo	Universidad Carlos III de Madrid
Juan Botia	King's College de Londres
Vicent Botti	Universitat Politècnica de València
Alberto Bugarín	Universidad de Santiago de Compostela
Humberto Bustince	Universidad Pública de Navarra
José M. Cadenas	Universidad de Murcia
Zoraida Callejas	Universidad de Granada
David Camacho	Universidad Autonoma de Madrid
Andrés Cano	Universidad de Granada
Iván Cantador	Universidad Autónoma de Madrid
Robert Castelo	Universitat Pompeu Fabra
Juan Corchado	Universidad de Salamanca
Óscar Corcho	Universidad Politécnica de Madrid
Rafael Corchuelo	Universidad de Seville
Óscar Cordón	Universidad de Granada
Sergio Damas	Universidad de Granada
Luis M. de Campos	Universidad de Granada
Andre de Carvalho	University of São Paulo
Luis De La Ossa	Universidad de Castilla-La Mancha
Juan José Del Coz	Universidad de Oviedo en Gijon
María José del Jesus	Universidad de Jaén
Javier Del Ser	Universidad del País Vasco / TECNALIA
Miguel Delgado	Universidad de Granada
José Dorronsoro	Universidad Autónoma de Madrid
Richard Duro	Universidade da Coruna
Francisco Javier Díez	Universidad Nacional de Educación a Distancia
Francisco Escolano	Universidad de Alicante
Mariano Fernández López	Universidad San Pablo CEU
Antonio Fernández-Caballero	Universidad de Castilla-La Mancha
Francesc J. Ferri	Universidad de Valencia
Aníbal R. Figueiras	Universidad Carlos III de Madrid
José Manuel Galán	Universidad de Burgos
José Gamez	University of Castilla-La Mancha
Pablo García Bringas	Universidad de Deusto



Raúl García-Castro	Universidad Politécnica de Madrid
Nicolás García-Pedrajas	Universidad de Córdoba
Rafael M. Gasca	Universidad de Sevilla
Pablo Gervás	Universidad Complutense de Madrid
Lluís Godó	Instituto de Investigación en Inteligencia Artificial - CSIC
Koldo Gojenola	Universidad del País Vasco
Juan Gomez Romero	Universidad de Granada
Antonio González	Universidad de Granada
Manuel Grana	Universidad del País Vasco
Joséchu Guerrero	Universidad de Zaragoza
Bertha Guijarro-Berdiñas	Universidad de A Coruña
Manuel Gómez-Olmedo	Universidad de Granada
Carlos Gómez-Rodríguez	Universidade da Coruña
José Hernandez-Orallo	Universitat Politècnica de València
Enrique Herrera-Viedma	Universidad de Granada
Cesar Hervás	Universidad de Córdoba
Juan F. Huete	Universidad de Granada
Inaki Inza	Universidad del País Vasco
José M. Iñesta	Universidad de Alicante
Luis Jimenez Linares	Universidad de Castilla-La Mancha
Jordi Levy	Instituto de Investigación en Inteligencia Artificial - CSIC
Carlos Linares Lopez	Universidad Carlos III de Madrid
Victoria Lopez	Universidad Complutense de Madrid
Ramon Lopez-Cozar Delgado	Universidad de Granada
Adolfo Lopez-Paredes	Universidad de Valladolid
David Losada	Universidad de Santiago de Compostela
Óscar Luaces	Universidad de Oviedo en Gijón
Lawrence Mandow	Universidad de Málaga
Felip Manyà	Instituto de Investigación en Inteligencia Artificial - CSIC
Rafael Martínez Tomas	Universidad Nacional de Educación a Distancia
Patricio Martínez-Barco	Universidad de Alicante
Luis Martínez	Universidad de Jaén
Paloma Martínez Fernández	Universidad Carlos III de Madrid
Andrés Masegosa	Universidad de Almería
Rafael Medina-Carnicer	Universidad de Córdoba
Belen Melian	Universidad de La Laguna
Pedro Meseguer	Instituto de Investigación en Inteligencia Artificial - CSIC
José M. Molina	Universidad Carlos III de Madrid
Rafael Molina	Universidad de Granada
Rafael Morales-Bueno	Universidad de Málaga
José Andrés Moreno Pérez	Universidad de La Laguna



Javier Muguerza	Universidad del País Vasco
Manuel Ojeda-Aciego	Universidad de Malaga
José Ángel Olivas	Universidad de Castilla-La Mancha
Sascha Ossowski	Universidad de Rey Juan Carlos
José Palma	Universidad de Murcia
Francisco Parreño	Universidad de Castilla-La Mancha
Miguel Ángel Patricio	Universidad Carlos III de Madrid
Antonio Peregrin	Universidad de Huelva
José M. Peña	Linköping University
Filiberto Pla	Universitat Jaume I
Hector Pomares	Universidad de Granada
José M Puerta	Universidad de Castilla-La Mancha
Domenec Puig	Universitat Rovira i Virgili
Rafael Ramirez	Universitat Pompeu Fabra
Beatriz Remeseiro	Universidad de Oviedo
José C. Riquelme	Universidad de Sevilla
Ramon Rizo	Universidad de Alicante
Horacio Rodríguez	Universitat Politècnica de Catalunya
Camino Rodríguez Vela	Universidad de Oviedo
Paolo Rosso	Universitat Politècnica de València
Antonio Salmeron	Universidad de Almería
José Salvador Sanchez	Universitat Jaume I
Luciano Sanchez	Universidad de Oviedo
Araceli Sanchis	Universidad Carlos III de Madrid
Encarna Segarra	Universitat Politècnica de València
Emilio Soria	Universidad de Valencia
María Taboada	Universidad de Santiago de Compostela
Alicia Troncoso	Universidad Pablo de Olavide
José A. Troyano	Universidad de Sevilla
L. Alfonso Ureña-López	Universidad de Jaén
Rafael Valencia-Garcia	Universidad de Murcia
Sebastián Ventura	Universidad de Córdoba
José Luis Verdegay	Universidad de Granada
María Amparo Vila	Universidad de Granada

## **XIX ESTYL F**

Rafael Alcalá	Universidad de Granada
Jesús Alcalá-Fdez	Universidad de Granada
Cristina Alcalde	Universidad del País Vasco
José María Alonso	Universidad de Santiago de Compostela
Sergio Alonso	Universidad de Granada
Eduarne Barrenechea	Universidad Pública de Navarra
Senén Barro	Universidad de Santiago de Compostela
José Manuel Benítez	Universidad de Granada



Fernando Bobillo	Universidad de Zaragoza
Alberto Bugarín	Universidad de Santiago de Compostela
Ana Burusco	Universidad Pública de Navarra
Humberto Bustince	Universidad Pública de Navarra
Francisco Javier Cabrerizo	Universidad de Granada
José Manuel Cadenas	Universidad de Murcia
Tomasa Calvo	Universidad de Alcalá
Pablo Carmona	Universidad de Extremadura
Jorge Casillas	Universidad de Granada
Juan Luis Castro	Universidad de Granada
José Jesús Castro-Sánchez	Universidad de Castilla-La Mancha
Óscar Cerdón	Universidad de Granada
Ulises Cortés	Universidad Politécnica de Cataluña
Inés Couso	Universidad de Oviedo
Susana Cubillo	Universidad Politécnica de Madrid
Rocio De Andrés	Universidad de Salamanca
María Jesús De la Fuente	Universidad de Valladolid
María José del Jesus	Universidad de Jaén
Miguel Delgado	Universidad de Granada
Susana Díaz	Universidad de Oviedo
Jorge Elorza	Universidad de Navarra
Juan Manuel Escaño	Universidad de Sevilla
Francesc Esteva	IIIA-CSIC
Francisco Javier Fernández	Universidad Pública de Navarra
Ramón Fuentes-González	Universidad Pública de Navarra
Mikel Galar	Universidad Pública de Navarra
José Luis García-Lapresta	Universidad de Valladolid
María Ángeles Gil	Universidad de Oviedo
Lluís Godo	IIIA-CSIC
Daniel Gómez	Universidad Complutense de Madrid
Antonio González	Universidad de Granada
Francisco Herrera	Universidad de Granada
Enrique Herrera-Viedma	Universidad de Granada
Aránzazu Jurío	Universidad Pública de Navarra
María Teresa Lamata	Universidad de Granada
Vicente Liern	Universidad de Valencia
Bonifacio Llamazares	Universidad de Valladolid
Carlos López-Molina	Universidad Pública de Navarra
Luis Magdalena	Universidad Politécnica de Madrid
Nicolás Marín Ruíz	Universidad de Granada
María José Martín-Bautista	Universidad de Granada
Luis Martínez	Universidad de Jaén
Sebastià Massanet	Universidad de las Islas Baleares
Francisco Mata	Universidad de Jaén
Gaspar Mayor	Universidad de las Islas Baleares



Jesús Medina	Universidad de Cádiz
José María Merigó	Universidad de Chile
José Manuel Molina-López	Universidad Carlos III de Madrid
Javier Montero	Universidad Complutense de Madrid
Susana Montes	Universidad de Oviedo
Francisco José Moreno-Velo	Universidad de Huelva
Manuel Mucientes	Universidad de Santiago de Compostela
Manuel Ojeda-Aciego	Universidad de Málaga
José Ángel Olivas	Universidad de Castilla-La Mancha
Miguel Pagola	Universidad Pública de Navarra
Daniel Paternain	Universidad Pública de Navarra
Antonio Peregrín	Universidad de Huelva
Raúl Pérez	Universidad de Granada
Héctor Pomares	Universidad de Granada
Carlos Porcel	Universidad de Jaén
Ana Pradera	Universidad Rey Juan Carlos
Adolfo R. de Soto	Universidad de León
Jordi Recasens	Universidad Politécnica de Cataluña
Ignacio Requena	Universidad de Granada
Juan Vicente Riera	Universidad de las Islas Baleares
Rosa María Rodríguez	Universidad de Granada
Ignacio Rojas	Universidad de Granada
Francisco Pascual Romero	Universidad de Castilla-La Mancha
Gregorio Sainz	Universidad de Valladolid
Daniel Sánchez	Universidad de Granada
Luciano Sánchez	Universidad de Oviedo
Santiago Sánchez-Solano	IMSE-CNM
José Antonio Sanz	Universidad Pública de Navarra
Jesús Serrano-Guerrero	Universidad de Castilla-La Mancha
Miguel Ángel Sicilia	Universidad de Alcalá
Alejandro Sobrino	Universidad de Santiago de Compostela
Vicenç Torra	University of Skövde
Joan Torrens	Universidad de las Islas Baleares
Aida Valls	Universidad Rovira i Virgili
José Luis Verdegay	Universidad de Granada
Amparo Vila	Universidad de Granada
Pedro Villar	Universidad de Granada

## XII MAEB

Jesús S. Aguilar-Ruiz	Universidad Pablo de Olavide
Enrique Alba	Universidad de Málaga
Ada Álvarez	Universidad Autónoma de Nuevo León
Ramón Álvarez-Valdés	Universidad de Valencia
Lourdes Araujo	UNED



Joaquín Bautista	Universitat Politècnica de Catalunya
Gema Bello	Universidad Autonoma de Madrid
José Manuel Benítez	Universidad de Granada
Enrique Bermejo	Universidad de Granada
Christian Blum	INRIA
Julio Brito	Universidad de la Laguna
Rafael Caballero	Universidad de Málaga
David Camacho	Universidad Autonoma de Madrid
Vicente Campos	Universidad de Valencia
Jorge Casillas	Universidad de Granada
Pedro A. Castillo	Universidad de Granada
Francisco Chávez	Universidad de Extremadura
Manuel Chica	Universidad de Granada
Francisco Chicano	Universidad de Málaga
Carlos A. Coello	Academia Mexicana de Computación, México
Ángel Corberán	Universidad de Valencia
Óscar Cordon	Universidad de Granada
Carlos Cotta	Universidad de Málaga
Sergio Damas	Universidad de Granada
María José del Jesus	Universidad de Jaén
Bernabé Dorronsoro	Universidad de Cadiz
Abraham Duarte	Universidad Rey Juan Carlos
Richard Duro	Universidad de A Coruña
José Egea	Universidad Politécnica de Cartagena
Javier Faulín	Universidad Pública de Navarra
Antonio J. Fernández	Universidad de Málaga
Alberto Fernández	Universidad de Granada
Juan Carlos Fernández	Universidad de Cordoba
Francisco Fernández	Universidad de Extremadura
Maribel G. Arenas	Universidad de Granada
Alfredo G. Hernández-Díaz	Universidad Pablo de Olavide
José Antonio Gámez	Universidad de Castilla-La Mancha
Carlos García	Universidad de Cordoba
Salvador García	Universidad de Granada
Nicolás García-Pedrajas	Universidad de Cordoba
Juan A. Gómez	Universidad de Extremadura
Antonio González	Universidad de Granada
Pedro González	Universidad de Jaen
Antonio González-Pardo	Universidad Autonoma de Madrid
Pedro Antonio Gutiérrez	Universidad de Córdoba
Francisco Herrera	Universidad de Granada
Cesar Hervás	Universidad de Córdoba
José Ignacio Hidalgo	Universidad Complutense de Madrid
Ángel A. Juan	Universitat Oberta de Catalunya
Manuel Laguna	Universidad de Colorado Boulder, Colorado EEUU



Juan Lanchares	Universidad Complutense de Madrid
Darío Landa Silva	Universidad de Nottingham, Reino Unido
Pedro Larrañaga	Universidad Politécnica de Madrid
Francisco Luna	Universidad de Córdoba
José María Luna	Universidad de Córdoba
Mariano Luque-Gallego	Universidad de Málaga
Rafael M. Luque-Baena	Universidad de Málaga
Rafael M. Luque-Baena	Universidad de Málaga
Luis Magdalena	Universidad Politécnica de Madrid
Rafael Marti	Universidad de la Laguna
Belén Melián	Universidad de la Laguna
Alexander Mendiburu	Universidad del País Vasco
Pablo Mesejo	Universidad de Córdoba
Daniel Molina	Universidad de Granada
Julián Molina	Universidad de Málaga
José A. Moreno	Universidad de la Laguna
Antonio J. Nebro	Universidad de Málaga
Julio Ortega	Universidad de Granada
Joaquín Pacheco	Universidad de Burgos
Eduardo G. Pardo	Universidad Politécnica de Madrid
María Del Carmen Pegalajar	Universidad de Granada
Juanjo Peiró	Universidad de Valencia
David Pelta	Universidad de Granada
Antonio Peregrín	Universidad de Huelva
Raúl Pérez	Universidad de Granada
Julio R. Banga	Instituto de Investigaciones Marinas. CSIC
Juan R. Rabuñal	Universidad de A Coruña
Helena Ramalhinho Lourenco	Universidad Pompeu Fabra
Roger Ríos	UANL
José Riquelme	Universidad de Sevilla
José Luis Risco-Martín	Universidad Complutense de Madrid
Víctor Rivas	Universidad de Jaén
Carlos Andrés Romano	Universidad Politécnica de Valencia
Alejandro Rosete Suárez	Universidad Tecnológica de la Habana, Cuba
Rubén Ruiz	Universidad Politécnica de Valencia
Yago Sáez	Universidad Carlos III de Madrid
Sancho Salcedo	Universidad de Alcalá
Luciano Sánchez	Universidad de Oviedo
Roberto Santana	Universidad del País Vasco
Thomas Stützle	INRIA
Leonardo Trujillo	Instituto Tecnológico de Tijuana, México
Ángel Udías	Universidad Rey Juan Carlos
Andrea Valsecchi	Universidad de Granada
Miguel Ángel Vega	Universidad de Extremadura
Sebastián Ventura	Universidad de Córdoba



José Luis Verdegay  
Pedro Villar  
Juan Villegas  
Gabriel Winter  
Amelia Zafra

Universidad de Granada  
Universidad de Granada  
Universidad Autónoma Metropolitana, México  
Universidad de Las Palmas de Gran Canaria  
Universidad de Córdoba

## IX TAMIDA

Olatz Arbelaitz  
Gualberto Asencio  
María Martínez Ballesteros  
José del Campo  
Alberto Cano  
Cristóbal Carmona  
Emilio Corchado  
Óscar Cordon  
Juan J. del Coz  
Francesc J. Ferri  
Jorge García Gutiérrez  
Salvador García López  
Nicolás García Pedrajas  
Karina Gibert  
Pedro González  
José Hernández Orallo  
Francisco Herrera  
M<sup>a</sup> José del Jesus  
Pedro Larrañaga  
José A. Lozano  
José M<sup>a</sup> Luna  
Francisco Martínez Álvarez  
Juan Nepomuceno  
M<sup>a</sup> Dolores Pérez  
Héctor Pomares  
M<sup>a</sup> José Ramírez  
Sergio Ramírez Gallego  
José C. Riquelme  
Antonio Rivera  
Juan J. Rodríguez  
Ignacio Rojas  
Miquel Sànchez i Marrè  
Alicia Troncoso Lora  
Pablo Varona  
Sebastián Ventura  
Marta Zorrilla

Universidad del País Vasco  
Universidad Pablo de Olavide  
Universidad de Sevilla  
Universidad de Málaga  
Universidad de Córdoba  
Universidad de Burgos  
Universidad de Salamanca  
Universidad de Granada  
Universidad de Oviedo  
Universidad de Valencia  
Universidad de Sevilla  
Universidad de Granada  
Universidad de Córdoba  
Universidad Politécnica de Cataluña  
Universidad de Jaén  
Universidad Politécnica de Valencia  
Universidad de Granada  
Universidad de Jaén  
Universidad Politécnica de Madrid  
Universidad del País Vasco  
Universidad de Córdoba  
Universidad Pablo de Olavide  
Universidad de Sevilla  
Universidad de Jaén  
Universidad de Granada  
Universidad Politécnica de Valencia  
Universidad de Granada  
Universidad de Sevilla  
Universidad de Jaén  
Universidad de Burgos  
Universidad de Granada  
Universidad Politécnica de Cataluña  
Universidad Pablo de Olavide  
Universidad Autónoma de Madrid  
Universidad de Córdoba  
Universidad de Cantabria



## CidReS 2018

Ricardo Aler	Universidad Carlos III
Mahmoud Barhamgi	Universidad de Lion, Francia
Gema Bello Orgaz	Universidad Autonoma de Madrid
Carlos Carrascosa	Universidad Politécnica de Valencia
Manuel Jesús Cobo	Universidad de Cádiz
Mari Luz Congosto	Universidad Carlos III
Óscar Cordón	Universidad de Granada
Carlos Cotta	Universidad de Málaga
Sergio Damas	Universidad de Granada
Abraham Duarte	Universidad Rey Juan Carlos
Luis Espinosa Anke	Cardiff University, Gran Bretaña
Francisco Fernández de Vega	Universidad de Extremadura
Antonio González Pardo	Universidad Autonoma de Madrid
Jason J. Jung	Universidad de Chung Ang, Korea del Sur
Raul Lara Cabrera	Universidad Autonoma de Madrid
María Teresa Martín Valdivia	Universidad de Jaén
Manuel Montes	Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE), México
Muntsa Padro	Eloquant, Francia
Sancho Salcedo	Universidad de Alcalá
Jesús Sanchez-Oro Calvo	Universidad Rey Juan Carlos
Frederique Segond	Viseo, Francia
Javier del Ser	Universidad del País Vasco / TECNALIA
Maite Taboada	Simon Fraser University, Canadá
Rafel Valencia	Universidad de Murcia
Benjamin Vargas	Universidad de Granada
Julian Vicente	Universidad Politécnica de Valencia
L. Alfonso Ureña López	Universidad de Jaén
Carmen Zarco	Universidad Internacional de La Rioja
Mourad Oussalah	Universidad de Oulu, Finlandia
Carla Vairetti	Universidad de Los Andes, Chile
José Manuel Perea Ortega	Universidad de Extremadura

## V CoSECiVi

Isabel Barbancho	Universidad de Málaga
Carlos Blanco Bueno	Universidad de Cantabria
David Camacho	Universidad Autónoma de Madrid
Miguel Chover	Universidad Jaume I
Antonio J. Fernández Leiva	Universidad de Málaga
Francisco J. Gallego Durán	Universidad de Alicante
Pablo García Sánchez	Universidad de Cádiz
Marco Antonio Gómez Martín	Universidad Complutense de Madrid



Pedro Antonio González Calero	Universidad Complutense de Madrid
Antonio González Pardo	Universidad Autónoma de Madrid
Pascual González	Universidad de Castilla-La Mancha
Javier Jaén	Universidad Politécnica de Valencia
Raúl Lara Cabrera	Universidad Autónoma de Madrid
Carlos León Aznar	Universidad Complutense de Madrid
Antonio M. Mora García	Universidad de Granada
Gustavo Patow	Universitat de Girona
Federico Peinado Gil	Universidad Complutense de Madrid
Luis Peña Sánchez	Universidad Rey Juan Carlos
Diego Perez Liebana	Queen Mary University of London, UK
Antonio Sánchez Ruiz-Granados	Universidad Complutense de Madrid

## II BigDADE

Amparo Alonso Betanzos	Universidade da Coruña
Jaume Bacardit	Newcastle University
Antonio Bahamonde	Universidad de Oviedo
José Manuel Benítez	Universidad de Granada
Concha Bielza	Universidad Politécnica de Madrid
Verónica Bolón	Universidade da Coruña
David Camacho	Universidad Autónoma de Madrid
Andrés Cano	Universidad de Granada
Emilio Corchado	Universidad de Salamanca
Óscar Cordon	Universidad de Granada
Juan José del Coz	Universidad de Oviedo
María José del Jesus	Universidad de Jaén
Javier del Ser	Universidad del País Vasco / TECNALIA
José Dorronsoro	Universidad Autónoma de Madrid
Anibal Figueiras	Universidad Carlos III de Madrid
Mikel Galar	Universidad Pública de Navarra
José A. Gámez	Universidad de Castilla la Mancha
Salvador García	Universidad de Granada
Cesar García-Osorio	Universidad de Burgos
Nicolás García-Pedrajas	Universidad de Córdoba
Manuel Gómez-Olmedo	Universidad de Granada
Pedro González	Universidad de Jaén
Bertha Guijarro	Universidade da Coruña
Francisco Herrera	Universidad de Granada
Pedro Larrañaga	Universidad Politécnica de Madrid
Victoria López	Universidad Complutense de Madrid
José Antonio Lozano	Universidad del País Vasco
David Martínez	University College of London
Antonio Peregrín	Universidad de Huelva
José M. Puerta	Universidad de Castilla la Mancha



José Riquelme	Universidad de Sevilla
Antonio Jesús Rivera	Universidad de Jaén
Antonio Salmerón	Universidad de Almería
Isaac Triguero	Gent University
Alicia Troncoso	Universidad Pablo de Olavide
Sebastián Ventura	Universidad de Córdoba

## DeepL 2018

Fernando de la Calle	Universidad Carlos III de Madrid
José Dorronsoro	Universidad Autónoma de Madrid
Lucas García	MathWorks
Pablo Mesejo	Universidad de Granada
Ricardo Guerrero Gómez-Olmedo	BEEVA
Francisco Javier Ordóñez	StyleSage
Andrés Ortiz	Universidad de Malaga
Gema Parreño Piqueras	BBVA
Petia Radeva	Universidad de Barcelona
Javier Ramírez	Universidad de Granada
Xavier Serra	Universidad de Pompeu Fabra

## IABiomed 2018

Manuel Campos	Universidad de Murcia
Paulo Felix	Universidad de Santiago de Compostela
Jesualdo T. Fernández-Breis	Universidad de Murcia
Juan Fernández-Olivares	Universidad de Granada
Pedro Larrañaga	Universidad Politécnica de Madrid
Beatriz López	Universidad de Girona
Rafael Martínez	UNED
José T. Palma	Universidad de Murcia
M. Jesús Taboada	Universidad de Santiago de Compostela

## IV FINO

Juan Manuel Corchado	Universidad de Salamanca
Ana Belén Gil González	Universidad de Salamanca
Ángel Arroyo	Universidad de Burgos
Belén Vaquerizo García	Universidad de Burgos
Javier Sedano	Instituto Tecnológico de Castilla y León
Jesús Ángel Román Gallego	Universidad de Salamanca
José Luis Calvo Rolle	Universidad de Coruña
José Luis Casteleiro Roca	Universidad de Coruña
Leticia Curiel	Universidad de Burgos



Pedro Antonio Hernández Ramos	Universidad de Salamanca
Hector Quintián	Universidad de Salamanca
Francisco Herrera	Universidad de Granada
Salvador García	Universidad de Granada
Julián Luengo	Universidad de Burgos
Edurne Barrenechea	Universidad Pública de Navarra
Luciano Sánchez	Universidad de Oviedo
Óscar Cordon	Universidad de Granada
Oriol Pujol	Universidad de Barcelona
Sergio Escalera	Universidad de Barcelona
Daniel Hernández-Lobato	Universidad Autónoma de Madrid
Aníbal Ramón Figueiras-Vidal	Universidad Carlos III de Madrid
Araceli Sanchís	Universidad Carlos III de Madrid
Agapito Ismael Ledezma	Universidad Carlos III de Madrid
Jesús M <sup>a</sup> Pérez	Universidad del País Vasco
José Antonio Sanz	Universidad Pública de Navarra
Santiago Porras	Universidad de Burgos

## **Industria 4.0 2018**

Sergio Gil-López	TECNALIA
Aritz Pérez	BCAM
Sancho Salcedo-Sanz	Universidad de Alcalá
Iñaki Inza	Universidad del País Vasco (UPV/EHU)
David Camacho	Universidad Autónoma de Madrid
Jesús Para	Universidad de Mondragón
Antonio J. Nebro	Universidad de Málaga
José Manuel Garcia-Nieto	Universidad de Málaga
Miren Nekane Bilbao	Universidad del País Vasco (UPV/EHU)
Urko Zurutuza	Universidad de Mondragón
Diego Galar	TECNALIA & Luleå University of Technology
Jonathan Ortigosa	GESTAMP
Miguel Ángel Veganzones	NEM Solutions

# Índice

## XVIII Conferencia de la Asociación Española para la Inteligencia Artificial (XVIII CAEPIA)

### CAEPIA 1: Modelos Gráficos Probabilísticos y Árboles de Decisión

Bayesian optimization of the PC algorithm for learning Gaussian Bayesian networks . . .	5
<i>Irene Córdoba, Eduardo C. Garrido-Merchán, Daniel Hernández-Lobato, Concha Bielza, Pedro Larrañaga</i>	
Asymmetric Hidden Markov Models with Continuous Variables . . . . .	6
<i>Carlos Puerto-Santana, Concha Bielza, Pedro Larrañaga</i>	
Un test de dos muestras multinomiales basado en modelos Bayesianos jerárquicos . . . . .	7
<i>Antonio Torres, Andrés Masegosa, Antonio Salmerón</i>	
A Linear Programming Based Approach for Evaluating Interval-valued Influence Diagrams . . . . .	13
<i>Rafael Cabañas de Paz, Andrés Cano, Manuel Gómez-Olmedo, Alessandro Antonucci</i>	
Algoritmos basados en árboles de decisión para partial label ranking . . . . .	15
<i>Juan Carlos Alfaro Jiménez, Juan Ángel Aledo Sánchez, José Antonio Gámez Martín</i>	
Fault predictive model for HVAC Systems in the context of Industry 4.0 . . . . .	21
<i>Inés Sittón-Candanedo</i>	

### CAEPIA 2: Sistemas de Recomendaciones

Neighbor selection for cold users in collaborative filtering . . . . .	29
<i>Alejandro Bellogín, Ignacio Fernández-Tobías, Iván Cantador, Paolo Tomeo</i>	
PMSC-UGR: A test collection for expert recommendation based on PubMed and Scopus	30
<i>Albusac César, Luis M. de Campos, Juan M. Fernández-Luna, Juan F. Huete</i>	
An Intelligent Advisor for City Traffic Policies . . . . .	31
<i>Daniel H. Stolfi, Christian Cintrano, José Francisco Chicano García, Enrique Alba</i>	



### CAEPIA 3: Navegación y Smart Cities

Analysis of Sensor Fusion Solutions for UAVs .....	35
<i>Jesús García, José Manuel Molina</i>	
Evasión de obstáculos apoyada en localización basada en simulación de instancias - Navegación autónoma en entornos cerrados .....	41
<i>Mario Bartolome Manovel, César Ignacio García-Osorio, José Francisco Díez-Pastor, Alejandro Merino Gómez</i>	
Medida de calidad de la planificación de recogida de residuos a partir del conocimiento del experto utilizando aprendizaje de preferencias .....	47
<i>Miriam Fernández Díaz, Laura Fernández Díaz, José Ramón Quevedo Pérez, Elena Montañés Rocas</i>	
Data science for building energy management: A review .....	53
<i>Miguel Molina-Solana, María Ros, M. Dolores Ruiz, Juan Gómez Romero, María J. Martín-Bautista</i>	
Inteligencia Artificial para la Inteligencia Urbana: Sistema de Ayuda a la Decisión para la predicción de la vulnerabilidad social .....	55
<i>Francisco Javier Abarca-Álvarez, Francisco Sergio Campos-Sanchez</i>	

### CAEPIA 4: Optimización y Computación de Altas Prestaciones

La importancia de un aplicativo web como ayuda para la conformación de grupos de tra- bajo colaborativo .....	63
<i>Franco Esteban Córdoba Pérez, Óscar Revelo Sánchez, Alexander Barón Salazar</i>	
Uso de CMSA para resolver el problema de selección de requisitos .....	68
<i>Miguel Ángel Domínguez Ríos, José Francisco Chicano García, Enrique Alba</i>	
A First Step to Accelerating Fingerprint Matching based on Deformable Minutiae Cluste- ring .....	74
<i>Andrés Jesús Sanchez Fernandez, Luis Felipe Romero Gómez, Siham Tabik, Miguel Ángel Medina Pérez, Francisco Herrera</i>	
Running Genetic Algorithms in the Edge: A First Analysis .....	75
<i>José Á. Morell, Enrique Alba</i>	

### CAEPIA 5: Inteligencia Artificial: Datos Abiertos, Problemas y Fundamentos

GraphDL: An Ontology for Linked Data Visualization .....	79
<i>Juan Gómez Romero, Miguel Molina-Solana</i>	
Aragon Open Data: A NLP-Based ontology population for Public Administration .....	80
<i>Paula Peña Larena, Rafael del Hoyo Alonso, Rocío Aznar Gimeno, Rosa Montañés Salas</i>	



Participatory Design with online Focus-group and Normative Systems .....	86
<i>Noelia García Castillo, Marlon Cardenas Bonett, Jorge Gómez-Sanz, Juan Pavon</i>	
An analysis of the perception of intelligence by different stakeholders in the Ambient Assisted Living domain .....	87
<i>Marlon Cardenas Bonett, Noelia García Castillo, Jorge Gómez-Sanz</i>	
Computational machines, free will and human reason .....	93
<i>Gonzalo Génova, Ignacio Quintanilla Navarro</i>	
Bireducts with tolerance relations .....	95
<i>María José Benítez Caballero, Jesús Medina, Eloisa Ramírez Poussa, Dominik Slezak</i>	
 <b>CAEPIA 6: Multimedia e Imágenes</b>	
A software tool for categorizing violin student renditions by comparison .....	99
<i>Miguel Delgado, Waldo Fajardo Contreras, Miguel Molina-Solana</i>	
Towards an Automated Composer of Popular Spanish Songs: Integrating a Music Generator and a Song Lyrics Generator .....	100
<i>María Navarro-Cáceres, Hugo Gonçalo Oliveira, Juan M. Corchado</i>	
Goal-Reasoning in StarCraft: Brood War through Multilevel Planning .....	107
<i>Moisés Martínez, Nerea Luis</i>	
A Graphic User Interface for Images Edge Detection. A Proposal to Combine Ant Colony Systems and Fuzzy Logic .....	114
<i>María Angélica Pinninghoff, Sebastián Espinoza, Ricardo Contreras</i>	
Doble modelo de fuerzas gravitacionales para procesamiento de imagen .....	120
<i>Cédric Marco-Detchart, Javier Fernández, Humberto Bustince</i>	
 <b>CAEPIA 7: Deep Learning</b>	
Time Series Decomposition for Improving the Forecasting Performance of Convolutional Neural Networks .....	129
<i>Iván Méndez-Jiménez, Miguel Cárdenas Montes</i>	
Comparing Deep Recurrent Networks Based on the MAE Random Sampling, a First Approach .....	130
<i>Andrés Camero, Jamal Toutouh, Enrique Alba</i>	
Background modeling for video sequences by stacked denoising autoencoders .....	131
<i>Jorge García-González, Juan M. Ortiz-De-Lazcano-Lobato, Rafael Marcos Luque-Baena, Miguel Ángel Molina-Cabello, Ezequiel López-Rubio</i>	
Predicción ordinal de rampas de viento usando Echo State Networks de complejidad reducida .....	132
<i>Manuel Dorado-Moreno, Pedro Antonio Gutiérrez, Sancho Salcedo-Sanz, Luis Prieto, César Hervás-Martínez</i>	



Detección de variedad y estado de maduración del ciruelo japonés utilizando imágenes hiperespectrales y aprendizaje profundo ..... 139  
*Francisco Chávez, Borja Rodríguez Puerta, Francisco Javier Rodríguez Díaz, Rafael Marcos Luque-Baena*

Preprocesamiento guiado por luminosidad para la detección automática de armas blancas en video vigilancia con Deep Learning ..... 145  
*Alberto Castillo, Siham Tabik, Francisco Pérez, Roberto Olmos, Francisco Herrera*

### **CAEPIA 8: Aprendizaje Automático**

Measuring the Quality of Machine Learning and Optimization Frameworks ..... 153  
*Ignacio Villalobos, Javier Ferrer, Enrique Alba*

Evaluation in learning from label proportions: an approximation to the precision-recall curve ..... 154  
*Jerónimo Hernández-González*

Identifying the machine learning family from black-box models ..... 155  
*Raül Fabra-Boluda, Cèsar Ferri, José Hernández-Orallo, Fernando Martínez-Plumed, María José Ramírez-Quintana*

Crowd Learning with Candidate Labeling: an EM-based Solution ..... 156  
*Iker Beñaran-Muñoz, Jerónimo Hernández-González, Aritz Pérez*

Aprendizaje automático con programación genética gramatical para la detección de patrones de diseño ..... 157  
*Rafael Barbudo, José Raúl Romero, Sebastián Ventura*

### **CAEPIA 9: Clasificación y Agrupamiento**

Learning Planning Action Models with Numerical Information and Logic Relationships using Classification Techniques ..... 165  
*José Á. Segura Muros, Juan Fernández-Olivares, Raul Pérez*

Adapting Hierarchical Multiclass Classification to changes in the target concept ..... 166  
*Daniel Andrés Silva Palacios, Cèsar Ferri, María José Ramírez-Quintana*

Clasificación ordinal de los grados de afectación de la enfermedad de Parkinson empleando imágenes de transportadores presinápticos de dopamina ..... 167  
*Julio Camacho-Cañamón, María-Victoria Guiote, Antonio-María Santos-Bueno, Ester Rodríguez-Cáceres, Elvira Carmona-Asenjo, Juan-Antonio Vallejo-Casas, Pedro Antonio Gutiérrez, César Hervás-Martínez*

Metodología Basada en Agrupamiento y Visualización para el Fenotipado de Pacientes . 173  
*José M. Juarez, Antonio Lopez Martínez-Carrasco, Antonio Morales, Francisco Palacios, Manuel Campos*



A boundary-point approach applied to gene selection in gene expression data .....	179
<i>Juan Ramos, José A. Castellanos-Garzón, Juan Francisco de Paz, Juan M. Corchado</i>	

## **XIX Congreso Español sobre Tecnologías y Lógica Fuzzy (XIX ESTYLF)**

### **ESTYLF 1: Sesión Especial: Funciones de Agregación y Conectivos Lógicos**

Complexity of Increasing $\phi$ -Recursive Computable Aggregations .....	187
<i>Ramón González del Campo, Luis Garmendia, Javier Montero</i>	
Relaciones de Indistinguibilidad Definidas Positivas .....	192
<i>Jordi Recasens, María Santos Tomás</i>	
Negaciones naturales asociadas a t-subnormas discretas .....	198
<i>Sebastia Massanet, Juan Vicente Riera, Joan Torrens</i>	
Estudio del Modus Tollens para implicaciones borrosas .....	204
<i>Isabel Aguiló, Jaume Suñer, Joan Torrens</i>	
Modus Ponens generalizado para (U,N)-implicaciones .....	210
<i>Margarita Mas, Daniel Ruiz-Aguilera, Joan Torrens</i>	
Caracterizaciones y equivalencias de algunas familias de funciones de implicación borrosas generadas a partir de cópulas .....	216
<i>Sebastia Massanet, Ana Pradera, Daniel Ruiz-Aguilera, Joan Torrens</i>	

### **ESTYLF 2: Aplicaciones I**

Toma de decisiones a gran escala usando evaluación parcial de criterios. Caso aplicado a evaluación de conferencias .....	221
<i>Jerónimo Duran, Rosana Montes, Francisco Herrera</i>	
Escalas cualitativas: Aplicación de un nuevo enfoque basado en proximidades .....	227
<i>Raquel González del Pozo, José Luis García Lapresta</i>	
Monitor-While-Drilling - based estimation of rock mass rating with computational intelligence: the case of tunnel excavation front .....	231
<i>Marta Galende-Hernández, María Jesús Fuente-Aparicio, Gregorio Ismael Sainz-Palmero, Manuel Menéndez</i>	
Nuevo Módulo de Conexión Inalámbrico vía Bluetooth con Arduino en la Librería JFML .....	233
<i>Francisco Jesús Arcos, José Manuel Soto-Hidalgo, Autilia Vitiello, Giovanni Acampora, Jesús Alcalá-Fdez</i>	
Un algoritmo de comparación de imágenes basado en funciones de semejanza de matrices .....	239
<i>Mikel Sesma-Sara, Laura de Miguel, Javier Fernández, Edurne Barrenechea, Radko Mesiar, Humberto Bustince</i>	



Detección del Fracaso Académico y Evaluación de la Práctica Docente mediante la Comunicación Automatizada con un Chatbot .....	245
<i>Jeovani Marcos Morales Nieto, Rosana Montes, Francisco Herrera</i>	

**ESTYLF 3: Sistemas Basados en Reglas Difusas**

Relevancia, Precisión e Interpretabilidad en Sistemas Basados en Reglas Difusas .....	253
<i>Marta Galende-Hernández, Isabel Rey, María Jesús Fuente-Aparicio, Gregorio Ismael Sainz-Palmero</i>	
Generación eficiente de reglas candidatas de calidad en problemas de alta dimensionalidad	259
<i>Javier Cózar, Luis de la Ossa, José Antonio Gámez Martín</i>	
Un modelo difuso lingüístico adaptativo para regresión con selección de reglas en Big Data .....	265
<i>Antonio Ángel Márquez, Ana María Roldán, Francisco Alfredo Márquez, Antonio Peregrín</i>	

**ESTYLF 4: Adquisición y Representación del Conocimiento**

Estudio sobre la evolución de la relación entre objetos y atributos en una sucesión de contextos L-Fuzzy .....	273
<i>Cristina Alcalde, Ana Burusco</i>	
Procesamiento Semántico Difuso Aplicado a un Modelo de Análisis de Textos basado en Grafos .....	279
<i>Wenny Hojas-Mazo, Alfredo Simón-Cuevas, José Ángel Olivas, Francisco P. Romero Chicharro</i>	
Definición de particiones difusas condicionadas usando transformadas difusas .....	285
<i>Nicolás Madrid, Sergio Díaz-Gómez</i>	

**ESTYLF 5: Sesión Especial: Soft Computing en Aprendizaje**

A PageRank-based method to extract fuzzy expressions as features in supervised classification problems .....	293
<i>Pablo Carmona, Juan Luis Castro, Jesús Lozano, José Ignacio Suárez</i>	
Un estudio sobre el uso de diferentes familias de funciones de fusión para la combinación de clasificadores en la estrategia Uno-contra-Uno .....	294
<i>Mikel Uriz, Daniel Paternain, Humberto Bustince, Mikel Galar</i>	
Clustering difuso con pertenencias intervalares .....	300
<i>Aránzazu Jurío, Humberto Bustince, Vicenc Torra</i>	
Assessing the performance of bipolar classifiers in three-class problems .....	306
<i>Guillermo Villarino, Daniel Gómez, J. Tinguaro Rodríguez</i>	



## **ESTYLF 6: Sesión Especial: Nuevos Enfoques y Aplicaciones en la Toma de Decisiones en Ambientes de Incertidumbre I**

A universal decision making model for restructuring networks based on Markov Random Fields .....	315
<i>Julia García Cabello, Enrique Herrera-Viedma</i>	
Un modelo de consenso para toma de decisiones en grupo a gran escala usando conjuntos difusos dudosos .....	316
<i>Rosa M. Rodríguez, Álvaro Labella, Luis Martínez</i>	
Free Double Hierarchy Hesitant Fuzzy Linguistic Term Sets in Group Decision-Making .....	322
<i>Jordi Montserrat-Adell, Zeshui Xu, Xunjie Gou, Núria Agell</i>	
Análisis de dependencias entre las variables de Arquitectura Empresarial empleando ecuaciones de relaciones difusas y su aplicación a la mejora de la toma de decisiones en las organizaciones .....	324
<i>Daniel Alfonso-Robaina, Juan Carlos Díaz-Moreno, Annette Malleuve-Martínez, Jesús Medina, Clemente Rubio Manzano</i>	
Supporting university career services by means of a multi-criteria decision-aiding system .....	330
<i>Jennifer Nguyen, Germán Sánchez-Hernández, Albert Armisen, Núria Agell, Xari Rovira, Cecilio Angulo</i>	

## **ESTYLF 7: Aplicaciones II**

Estudio empírico sobre el tratamiento de la sinonimia en los razonamientos vagos .....	335
<i>Gael Velasco Benito, Alejandro Sobrino Cerdeiriña, Alberto Bugarín</i>	
Uso de Expresiones Lingüísticas Comparativas en AFRYCA 3.0 .....	341
<i>Álvaro Labella, Rosa M. Rodríguez, Luis Martínez</i>	
Ajuste a una progresión hipotética de aprendizaje .....	347
<i>Itziar García-Honrado</i>	
Caracterizando a los usuarios a través de sus opiniones .....	353
<i>Jesús Serrano-Guerrero, Francisco P. Romero Chicharro, José Ruiz Morilla, José Ángel Olivas</i>	
Engine health monitoring with fuzzy data: lessons learned from aircraft industry .....	359
<i>Luciano Sánchez, Inés Couso</i>	
Análisis de distintas propuestas de sistemas de recomendaciones lingüísticos difusos para personalizar información en bibliotecas digitales .....	365
<i>Carlos Porcel, Alberto Ching-López, Álvaro Tejeda-Lorente, Juan Bernabé-Moreno, Enrique Herrera-Viedma, Francisco Javier Cabrerizo, Sergio Alonso</i>	

**ESTYLF 8: Fundamentos de Lógica Fuzzy**

Equivalence relations on fuzzy subgroups .....	369
<i>Carlos Bejines López, María Jesús Chasco, Jorge Elorza, Susana Montes</i>	
An alternative axiomatization for a fuzzy modal logic of preferences .....	370
<i>Amanda Vidal Wandelmer, Francesc Esteva, Lluís Godo</i>	
Stable models in multi-adjoint normal logic programs .....	376
<i>María Eugenia Cornejo, David Lobo, Jesús Medina</i>	
Galois connections between a fuzzy preordered structure and a general fuzzy structure .	378
<i>Inma P. Cabrera, Pablo Cordero, Francisca García-Pardo, Manuel Ojeda-Aciego, Bernard De Baets</i>	
Operations between fuzzy multisets .....	380
<i>Ángel Riesgo, Pedro Alonso, Irene Diaz, Susana Montes</i>	
Un marco semántico general para la Lógica de Simplificación .....	382
<i>Pablo Cordero, Manuel Enciso, Ángel Mora Bonilla, Vilem Vychodil</i>	

**ESTYLF 9: Sesión Especial: Aplicaciones de Funciones de Agregación y Pre-agregación**

Condiciones de monotonía direccional: interpretación geométrica .....	387
<i>Laura de Miguel, Mikel Sesma-Sara, Antonio Roldán, Julio Lafuente, Radko Mesiar, Humberto Bustince</i>	
Operadores de agregación y comparación para diferenciación de señales discretas .....	393
<i>Carlos Lopez-Molina, Sara Iglesias-Rey, Humberto Bustince, Nicolás Madrid</i>	
Una nueva aproximación al concepto de similitud intervalar teniendo en cuenta la longitud de los intervalos .....	399
<i>Humberto Bustince, Javier Fernández, Laura de Miguel, José Antonio Sanz Delgado, Mikel Sesma-Sara</i>	
Una generalización del algoritmo gravitacional de clústering utilizando funciones de overlap .....	405
<i>Iosu Rodríguez, Javier Ruiz-Aranguren, Javier Fernández, Humberto Bustince, Javier Armentia</i>	
Una definición de la Integral de Choquet intervalo-valorada basada en permutaciones admisibles .....	410
<i>Daniel Paternain, Laura de Miguel, Gustavo Ochoa, Inmaculada Lizasoain, Humberto Bustince, Radko Mesiar</i>	
Aggregation on relaxed indistinguishability operators based on different triangular norms	415
<i>Tomasa Calvo, Pilar Fuster Parra, Óscar Valero</i>	



### **ESTYLF 10: Sesión Especial: Nuevos Enfoques y Aplicaciones en la Toma de Decisiones en Ambientes de Incertidumbre II**

Fuzzy information and contexts for designing Automatic Decision-making Systems . . . .	423
<i>José Luis Verdegay, María Teresa Lamata, David Pelta</i>	
OWA operators in the calculation of the average green-house gases emissions . . . . .	424
<i>Keivan Amirbagheri, José M. Merigó</i>	
Fuzzy linguistic ranking model for Web Accessibility Test tools . . . . .	430
<i>Noe Zermeño, Lucas Daniel del Rosso Calache, Rosana Montes, Francisco Herrera</i>	
Estabilidad de las decisiones en el tiempo, ¿cómo medirla? . . . . .	436
<i>Rocío de Andrés, J. Manuel Cascon, Teresa González-Arteaga</i>	
Some remarks on “Preference stability over time: The time cohesiveness measure” . . . . .	442
<i>Teresa González-Arteaga, Rocío de Andrés</i>	

### **ESTYLF 11: Sesión Especial: Soft Computing y Generación del Lenguaje Natural I**

Modelado borroso de referencias geográficas textuales sobre datos de expertos . . . . .	447
<i>Alejandro Ramos Soto, José María Alonso, Ehud Reiter, Kees van Deemter, Albert Gatt</i>	
Indistinguibilidad y Modelado de Tamaño en Sistemas Data-to-text . . . . .	453
<i>Nicolás Marín, Gustavo Rivas-Gervilla, Daniel Sánchez</i>	
Método para medir la credibilidad de los agentes en videojuegos empleando Descripción Lingüística de Fenómenos Complejos y su aplicación como herramienta de apoyo en el proceso de enseñanza-aprendizaje en un curso de Inteligencia Artificial . . . . .	459
<i>Clemente Rubio Manzano, Tomás Lermana, Christian Vidal-Castro, Alejandra Segura-Navarrete, Claudia Martínez-Araneda</i>	
Statistical Language Modelling for Automatic Story Generation . . . . .	465
<i>Marta Vicente, Cristina Barros, Elena Lloret</i>	

### **ESTYLF 12: Sesión Especial: Soft Computing y Generación del Lenguaje Natural II**

Descripciones lingüísticas de datos de observación meteorológica usando temple simulado . . . . .	469
<i>Andrea Cascallar Fuentes, Alejandro Ramos Soto, Alberto Bugarín</i>	
Modelado lingüístico y síntesis de series temporales heterogéneas de consumo energético . . . . .	475
<i>Sergio Martínez-Municio, Luis Jiménez-Linares, Luis Rodríguez-Benítez, Ester Castillo-Herrera, Juan Giralt-Muiña</i>	
Generación Automática de Explicaciones en Lenguaje Natural para Árboles de Decisión de Clasificación . . . . .	481
<i>Bruno López-Trigo, José María Alonso, Alberto Bugarín</i>	



Descripción de series de tiempo utilizando Fuzzy Piecewise Linear Segments . . . . .	487
<i>Juan Moreno Garcia, Antonio Moreno-Garcia, Luis Jiménez-Linares, Luis Rodríguez-Benítez</i>	

**XIII Congreso Español en Metaheurísticas y Algoritmos Evolutivos y Bioinspirados (XIII MAEB)**

**MAEB 1: Aplicaciones de las Metaheurísticas**

Evolving Geographically-embedded Complex Networks using the CRO-SL Algorithm .	497
<i>Sancho Salcedo-Sanz, Lucas Cuadra</i>	
Metaheurísticas para calibración de modelos basados en agentes en dinámicas de adopción premium . . . . .	503
<i>Ignacio Moya, Manuel Chica, William Rand, Óscar Cordón</i>	
An empirical validation of a new memetic CRO algorithm for the approximation of time series . . . . .	509
<i>Antonio Manuel Durán-Rosal, Pedro Antonio Gutiérrez, Sancho Salcedo-Sanz, César Hervás-Martínez</i>	
Modelling Mandible Articulation for Skull-Face Overlay in Forensic Identification . . . . .	510
<i>Enrique Bermejo, Carmen Campomanes-Álvarez, Andrea Valsecchi, Óscar Ibáñez, Sergio Damas, Óscar Cordón</i>	
Propuestas de mejora para la evaluación del arte evolutivo . . . . .	512
<i>Francisco Fernández de Vega, Cayetano Cruz García, Patricia Hernández</i>	
An Evolutionary Approach to Metroidvania Videogame Design . . . . .	518
<i>Álvaro Gutiérrez Rodríguez, Carlos Cotta, Antonio José Fernández Leiva</i>	

**MAEB 2.1: Sesión Especial: Scatter Search y Path Relinking**

GRASP with Path Relinking for the Constrained Incremental Graph Drawing Problem .	527
<i>Anna Martínez-Gavara, Antonio Napoletano, Paola Festa, Tommaso Pastore, Rafael Martí</i>	
Detección de puntos débiles en redes utilizando GRASP y Path Relinking . . . . .	531
<i>Sergio Pérez-Peló, Jesús Sánchez-Oro, Abraham Duarte</i>	
Where facility centers should be located? . . . . .	537
<i>Ana Dolores López-Sánchez, Jesús Sánchez-Oro, Alfredo García Hernández-Díaz, Manuel Laguna</i>	

**MAEB 2.2: Scatter Search y VNS**

Encontrando grafos bipartitos completos mediante Búsqueda de Vecindad Variable . . . . .	545
<i>Juan David Quintana, Jesús Sánchez-Oro, Abraham Duarte</i>	



Búsqueda de Vecindad Variable para el problema de la agrupación y recogida de pedidos online en almacenes logísticos .....	551
<i>Sergio Gil-Borrás, Abraham Duarte, Antonio Alonso-Ayuso, Eduardo García Pardo</i>	

Una metaheurística paralela para grandes problemas de optimización dinámica entera mixta, con aplicaciones en la biología computacional .....	557
<i>David Rodríguez Penas, David Henriques, Patricia González, Ramón Doallo, Julio Sáez-Rodríguez, Julio R Banga</i>	

### MAEB 3: Heurísticas, Hiperheurísticas y Metaheurísticas

Genetic programming to evolve priority rules for on-line scheduling on single machine with variable capacity .....	561
<i>Francisco Gil-Gala, Carlos Mencía, María R. Sierra, Ramiro Varela</i>	

On the Landscape of a Problem of Finding Satisfactory Metaheuristics .....	567
<i>José M. Cecilia, Baldomero Imbernón, José Matías Cutillas Lozano, Domingo Gimenez</i>	

Generador de Planificaciones Conjuntas para Cuadrante de Rotación de los Conductores de Autobuses .....	573
<i>Eva María Almansa Aránega, Samuel López Liñán, Francisco José Rodríguez Serrano, José Manuel Benítez</i>	

### MAEB 4: Sesión Especial: Smart Cities

Monitorización y clasificación de estancias en edificios empleando captación de comunicaciones inalámbricas de dispositivos inteligentes .....	581
<i>Antonio Fernández-Ares, María Isabel García Arenas, Pedro A Castillo Valdivieso</i>	

Reduction of the Size of Datasets by using Evolutionary Feature Selection: the Case of Noise in a Modern City .....	587
<i>Javier Luque, Jamal Toutouh, Enrique Alba</i>	

Studying Solutions of the p-Median Problem for the Location of Public Bike Stations ..	588
<i>Christian Cintrano, Thomas Stützle, José Francisco Chicano García, Enrique Alba</i>	

### MAEB 5: Sesión Especial: Algoritmos MultiObjetivo

An Improvement Study of the Decomposition-based Algorithm Global WASF-GA for Evolutionary Multiobjective Optimization .....	591
<i>Sandra González-Gallardo, Rubén Saborido, Ana B. Ruiz, Mariano Luque</i>	

Pruning Dominated Policies in Multiobjective Pareto Q-learning .....	592
<i>Lawrence Mandow, José-Luis Pérez de la Cruz</i>	

Estudio de escalabilidad de implementaciones multiobjetivo en problemas con muchos objetivos .....	593
<i>Aurora Ramírez, Rafael Barbudo, José Raúl Romero, Sebastián Ventura</i>	



Algoritmo Evolutivo con División del Espacio de los Objetivos en base a la Solución Nadir: Un Estudio Comparativo sobre el Problema de la Mochila 0/1 Bi-Objetivo .....	599
<i>Máximo Méndez, Daniel Alejandro Rossit, Mariano Frutos, Begoña González</i>	
Algoritmo Evolutivo Multi-Objetivo para la Toma de Decisiones Interactiva en Optimización Dinámica .....	605
<i>Cristóbal Barba-González, José García-Nieto, Ana B. Ruiz, Antonio J. Nebro, Mariano Luque, José F. Aldana Montes</i>	

**MAEB 6: Metaheurísticas en Producción, Logística y Dirección de Operaciones**

A GRASP algorithm to optimize Operational Costs and Regularity of Production in mixed-model sequencing problems with forced interruption of operations .....	613
<i>Joaquín Bautista, Rocío Alfaro</i>	
Metaheurísticas constructivas para Car Sequencing Problem con Flotas de vehículos especiales .....	614
<i>Ignacio Moya, Joaquín Bautista, Manuel Chica, Sergio Damas, Óscar Cordón</i>	
Secuenciación en líneas de fabricación no sincronizadas con ensamblajes .....	620
<i>Carlos Andres, Julien Maheut</i>	
Equilibrado robusto de una línea de motores mixtos con atributos temporales, espaciales y ergonómicos .....	626
<i>Joaquín Bautista, Manuel Chica, Óscar Cordón, Sergio Damas</i>	

**MAEB 7.1: Sesión Especial: Aplicaciones de Simheuristics en Logística, Transporte y Ciudades Inteligentes**

Agile Optimization for Routing Unmanned Aerial Vehicles under Uncertainty .....	635
<i>Javier Panadero, Alfons Freixes, Ángel A. Juan, José M. Mozos</i>	
A Simheuristic Algorithm for the Team Orienteering Problem .....	641
<i>Javier Faulin, Ángel A. Juan, Lorena Silvana Reyes-Rubiano, Javier Panadero, Carlos Ospina, José M. Mozos</i>	
Current Trends in Simheuristics: from smart transportation to agent-based simheuristics .....	644
<i>Alejandro Estrada-Moreno, Ángel Juan, Javier Panadero, Carles Serrat, Alfons Freixes</i>	
Designing e-commerce supply chains: a stochastic facility–location approach .....	646
<i>Helena Ramalinho, Ángel Juan, Adela Pagés-Bernaus, Laura Calvet</i>	

**MAEB 7.2: Algoritmos Multiobjetivo y Aplicaciones**

Resumen extractivo de texto multidocumento usando un enfoque de optimización multi-objetivo basado en colonia de abejas artificiales .....	651
<i>Jesús M. Sánchez-Gómez, Miguel A. Vega-Rodríguez, Carlos J. Pérez</i>	



Algoritmo Multiobjetivo de Colonia de Abejas Artificiales aplicado al Problema de Orientación .....	657
<i>Rodrigo Martín-Moreno, Miguel A. Vega-Rodríguez</i>	

### MAEB 8.1: Algoritmos Multiobjetivo y Aplicaciones

Metaheurísticas híbridas para el problema del apagado de celdas en redes 5G .....	665
<i>Pablo Zapata, Francisco Luna, Juan F. Valenzuela-Valdés, Antonio Miguel Mora, Pablo Padilla</i>	

MOEA-EFEP: Un algoritmo evolutivo multi-objetivo para la extracción de patrones emergentes difusos .....	671
<i>Ángel Miguel García-Vico, Cristóbal José Carmona, Pedro González, María José del Jesus</i>	

### MAEB 8.2: Sesión Especial: Algoritmos Paralelos

Explotación de Paralelismo Multinivel e Híbrido en Metaheurísticas Híbridas .....	675
<i>José M. Cecilia, Baldomero Imbernón, Javier Cuenca, José Matías Cutillas Lozano, Domingo Gimenez</i>	

Optimización evolutiva multiobjetivo distribuida mediante aplicación selectiva de operadores .....	681
<i>Pablo García Sánchez, Julio Ortega, Jesús González Peñalver, Pedro Castillo, Juan Julián Merelo, Antonio Miguel Mora, Antonio Fernández-Ares</i>	

Análisis de Diseños Paralelos Multiobjetivo y Políticas de Planificación en Biología Evolutiva .....	687
<i>Sergio Santander-Jiménez, Miguel A. Vega-Rodríguez, Leonel Sousa</i>	

Developing Genetic Algorithms using Different MapReduce Frameworks: MPI vs. Hadoop .....	693
<i>Carolina Salto, Gabriela Minetti, Enrique Alba, Gabriel Luque</i>	

### MAEB 9: Sesión Especial: Aplicaciones en Medicina y Biotecnología

Strain Design as Multiobjective Network Interdiction Problem: A Preliminary Approach	697
<i>Marina Torres, Shouyong Jiang, David Pelta, Marcus Kaiser, Natalio Krasnogor</i>	

Un análisis de soluciones basadas en Programación Genética para resolver problemas de regresión simbólica de datos de medidores continuos de glucosa .....	698
<i>José Ignacio Hidalgo, J. Manuel Velasco, Sergio Contador, Juan Lanchares, Óscar Garnica</i>	

Registrado de Imagen Médica mediante Algoritmos de Optimización basados en Arrecifes de Coral .....	706
<i>Enrique Bermejo, Manuel Chica Serrano, Sergio Damas, Sancho Salcedo-Sanz, Óscar Cerdón</i>	



Registrado de imágenes 3D-2D para identificación forense mediante comparación de radiografías ..... 712  
*Óscar Gómez, Óscar Ibáñez, Andrea Valsecchi, Óscar Cordón, Tzipi Kahana*

Ajuste de un modelo de crecimiento de tumores de vejiga mediante PSO y predicción con incertidumbre ..... 718  
*David Martínez-Rodríguez, Clara Burgos-Simón, Juan Carlos Cortés, José Ignacio Hidalgo, Rafael Villanueva*

On the Use of Fitness Sharing in Studying the Genetic Code Optimality ..... 722  
*José Santos, Ángel Monteagudo*

**MAEB 10: Computación Evolutiva: Fundamentos y Modelos I**

Toolkit for the Automatic Comparison of Optimizers (TACO): Herramienta online avanzada para comparar metaheurísticas ..... 727  
*Daniel Molina, Antonio LaTorre*

Creating Difficult Instances of the Linear Ordering Problem ..... 733  
*Aritz Pérez, Josu Ceberio*

Anatomy of the Attraction Basins: Breaking with the Intuition ..... 739  
*Leticia Hernando, Alexander Mendiburu, José Antonio Lozano*

SHADE con Búsqueda Local Iterativa para Optimización Global de Alta Dimensionalidad ..... 741  
*Daniel Molina, Antonio LaTorre, Francisco Herrera*

An insight into evolutionary algorithms for continuous optimization: Learning by competitions ..... 747  
*Daniel Molina, Antonio LaTorre, Francisco Herrera*

**MAEB 11: Computación Evolutiva: Fundamentos y Modelos II**

Un estudio sobre la influencia de la función objetivo en evolución gramatical para regresión simbólica ..... 751  
*José Manuel Colmenar, José Ignacio Hidalgo*

Un análisis preliminar de nuevos modelos de mutación dirigida en algoritmos genéticos. .... 757  
*Borja Rodríguez Puerta, Francisco Díaz Barrancas, Francisco Chávez, Francisco Fernández de Vega*

Choosing population sizes to enhance Brain Storm Optimization algorithms ..... 763  
*Ricardo García-Ródenas, Luis Jiménez-Linares, Julio Alberto López Gómez*

Distance-based Exponential Probability Models for Constrained Combinatorial Problems ..... 769  
*Josu Ceberio, Alexander Mendiburu, José Antonio Lozano*



## IX Simposio de Teoría y Aplicaciones de la Minería de Datos (IX TAMIDA)

### TAMIDA 1: Modelos Predictivos

Identifying ecosystem patterns from time series of anchovy ( <i>Engraulis ringens</i> ) and sardine ( <i>Sardinops Sagax</i> ) landings in northern Chile .....	775
<i>Francisco Plaza, Rodrigo Salas, Eleuterio Yáñez</i>	
Análisis Big Data para la Respuesta a la Demanda en el Mercado Eléctrico .....	777
<i>José A. Fábregas, José María Luna, Ángel Arcos-Vargas, José C. Riquelme-Santos, Javier Tejedor</i>	
Un procedimiento efectivo para descomponer y modelar series temporales en agricultura .....	784
<i>Francisco Aragón, Francisco Javier Baldán, Manuel Parra, José Manuel Benítez</i>	
¿Requiere la clasificación de series temporales métodos específicos? .....	790
<i>Amaia Abanda, Usue Mori, José Antonio Lozano</i>	
Reglas de Asociación en Flujos de Datos para Monitorizar Actividad de Teléfonos Móviles .....	796
<i>Elena Ruiz, Jorge Casillas</i>	
Un Sistema de Recomendación de Asignaturas Multi-Criterio con Optimización Genética .....	802
<i>Aurora Esteban, Amelia Zafra, Cristóbal Romero</i>	
Reconocimiento de genes en secuencias de ADN por medio de imágenes. ....	808
<i>Luis Ángel Santamaría-Colula, Sarahi Zúñiga Herrera, Ivo H. Pineda Torres, María J. Somodevilla, Mario Rossainz-Lopez</i>	

### TAMIDA 2: Modelos Descriptivos

Reglas de Asociación en Datos Multi-Instancia mediante Programación Genética Gramatical .....	815
<i>José María Luna, Óscar Reyes Pupo, María José del Jesus, Sebastián Ventura</i>	
Aproximación al índice externo de validación de clustering basado en chi cuadrado ....	821
<i>José María Luna, Jorge García-Gutiérrez, María Martínez-Ballesteros, José C. Riquelme-Santos</i>	
Atipicidad: Medida de calidad clave dentro del descubrimiento de reglas descriptivas supervisadas .....	827
<i>Cristóbal José Carmona, María José del Jesus, Francisco Herrera</i>	

### TAMIDA 3: Aplicaciones

Modeling the navigation on enrolment web information area of a university using machine learning techniques .....	831
<i>Ainhoa Yera, Iñigo Perona, Olatz Arbelaitz, Javier Muguerza</i>	



Risk factors for development of antibiotic resistance of <i>Enterococcus faecium</i> to Vancomycin. A subgroup discovery approach. ....	832
<i>Andrej Fajfar, Manuel Campos, Francisco Palacios, Bernardo Cánovas-Segura, Gregor Stiglic, Roque Marín</i>	
Algoritmos de aprendizaje automático para predicción de niveles de niebla usando ventanas estáticas y dinámicas. ....	833
<i>Miguel Díaz-Lozano, David Guijo-Rubio, Pedro Antonio Gutiérrez, Carlos Casanova-Mateo, Sancho Salcedo-Sanz, César Hervás-Martínez</i>	
Intelligent Management of Measurement Units Equivalences in Food Databases .....	839
<i>Beatriz Sevilla-Villanueva, Karina Gibert, Miquel Sànchez-Marrè</i>	
Predicción de delincuencia con datos públicos .....	840
<i>Roberto Cuesta Calvo, Jesús Maudes, José-Francisco Díez-Pastor, Ivan Arjona-Alonso</i>	

**TAMIDA 4: Metodologías**

Diagnóstico de fallos mediante clasificadores: Análisis de robustez en ambientes de incertidumbre .....	849
<i>J.M. Bernal de Lázaro, Orestes Llanes Santiago, Alberto Prieto-Moreno, Antônio José da Silva Neto, Carlos Cruz Corona</i>	
shinytests: Una herramienta gráfica para la comparación estadística en minería de datos	855
<i>Jacinto Carrasco, Salvador García, Francisco Herrera</i>	
Extracción de factores relevantes en el análisis de datos biomédicos: una metodología basada en técnicas de aprendizaje supervisado .....	861
<i>Óscar Reyes, José M. Moyano, Antonio Rivero-Juárez, Raúl M. Luque, Antonio Rivero, Justo Castaño, Sebastián Ventura</i>	
Aplicaciones de la técnica de topic model en repositorios software .....	867
<i>Carlos López-Nozal, César Ignacio García-Osorio, Álar Arnáiz-González, Mario Juez-Gil</i>	

**TAMIDA 5: Preprocesamiento de Datos**

Feature Dimensionality vs. Distribution of Sample Types: A Preliminary Study on Gene-Expression Microarrays .....	875
<i>J. Salvador Sánchez, Vicente García</i>	
Selección de características distribuida en entornos heterogéneos .....	881
<i>Verónica Bolón-Canedo, Rubén Seoane-Martínez, José Luis Morillo-Salas, Amparo Alonso-Betanzos</i>	
Local sets for multi-label instance selection .....	887
<i>Álar Arnáiz-González, José Francisco Díez-Pastor, Juan J. Rodríguez, César Ignacio García-Osorio</i>	



Emerging topics and challenges of learning from noisy data in non-standard classification: A survey beyond binary class noise .....	889
<i>Ronaldo Prati, Julián Luengo, Francisco Herrera</i>	
Training Set Selection for Monotonic Ordinal Classification .....	891
<i>José Ramón Cano, Salvador García</i>	
Data source analysis in mood disorder research .....	893
<i>Pavel Llamocca, Milena Čukić, Axel Junstrand, Diego Urgelés, Victoria López</i>	

### TAMIDA 6: Problemas No Estándar

JCLAL 2.0: mejoras y nuevas funcionalidades en la herramienta Java de código abierto para el aprendizaje activo .....	901
<i>Eduardo Pérez, Luis D. González, Luis M. Sánchez, Óscar Reyes, Sebastián Ventura</i>	
Resolviendo el problema de regresión multi-salida mediante Gene Expression Program- ming .....	907
<i>Óscar Reyes, José M. Moyano, José María Luna, Sebastián Ventura</i>	
Análisis de algoritmos de cuantificación basados en ajuste de distribuciones .....	913
<i>Alberto Castaño, Laura Morán-Fernández, Jaime Alonso, Verónica Bolón-Canedo, Amparo Alonso-Betanzos, Juan José del Coz</i>	
$k$ -Vecinos más Cercanos Difuso para Clasificación Monotónica .....	919
<i>Sergio González, Salvador García, Sheng-Tun Li, Robert John, Francisco Herrera</i>	
Eventos raros, anomalías y novedades vistas desde el paraguas de la clasificación super- visada .....	925
<i>Ander Carreño, Iñaki Inza, José Antonio Lozano</i>	
Una librería para el aprendizaje Multi-instancia Multi-etiqueta .....	931
<i>Álvaro Belmonte, Amelia Zafra, Eva Gibaja, Sebastián Ventura</i>	

### TAMIDA 7: Deep Learning

Una primera aproximación a la predicción de variables turísticas con Deep Learning ...	939
<i>Daniel Trujillo Viedma, Antonio Jesús Rivera Rivas, Francisco Charte Ojeda, María José del Jesus</i>	
Detección de cáncer de piel usando técnicas de aprendizaje profundo .....	944
<i>Alejandro Polvillo-Hall, Juan A. Álvarez-García, Cristina Rubio-Escudero</i>	
A practical tutorial on autoencoders for nonlinear feature fusion: Taxonomy, models, soft- ware and guidelines .....	949
<i>David Charte, Francisco Charte, Salvador García, María José del Jesus, Francisco Herrera</i>	



## I Workshop en Ciencia de Datos en Redes Sociales (CidReS 2018)

### CidReS: Sesión 1

Using Facebook Reactions to Recognize Emotion in Political Domain .....	955
<i>Flor Miriam Plaza del Arco, Salud María Jiménez Zafra, María Teresa Martín Valdivia, Luis Alfonso Ureña López</i>	
Visualización avanzada de datos de Twitter para su análisis como canal de comunicación	961
<i>Carmen Zarco, Óscar Cordón</i>	
Identifying conflicts of interest of reviewers using authors bibliometric networks .....	967
<i>Verónica Duarte-Martínez, Antonio Gabriel López-Herrera, Manuel Jesús Cobo</i>	
Science Mapping Artificial Intelligence .....	973
<i>Benjamín Vargas-Quesada, Zaida Chinchilla Rodríguez, Antonio Perianes-Rodríguez</i>	

### CidReS: Sesión 2

On the analysis of the influence of the evaluation metric in community detection using GRASP .....	981
<i>Sergio Pérez-Peló, Jesús Sánchez-Oro, Abraham Duarte</i>	
Analizando la influencia de los atentados del 11-M en las elecciones generales de 2004: un enfoque ABM .....	987
<i>Ignacio Moya, Manuel Chica, José L. Sáez-Lozano, Óscar Cordón</i>	
Análisis de la influencia de los sentimientos en el proceso de detección de tópicos en redes sociales .....	989
<i>Karel Gutiérrez-Batista, Jesús R. Campaña, María-Amparo Vila, María J. Martín-Bautista</i>	
Un Algoritmo Memético, con búsqueda local basada en Label Propagation, para detectar comunidades en redes dinámicas .....	995
<i>Ángel Panizo Lledot, Gema Bello-Orgaz, Alfonso Ortega, David Camacho</i>	
Design of an ACO algorithm for Solving Community Finding Problems .....	1001
<i>Antonio González-Pardo, David Camacho</i>	

### CidReS: Sesión 3

Red Neural Recurrente para la Desambiguación de Entidades en Datos de Medios Sociales	1005
<i>Cristina Zuheros, Siham Tabik, Ana Valdivia, Eugenio Martínez-Cámara, Francisco Herrera</i>	
Detección de nodos tramposos en procesos de consenso en redes .....	1011
<i>Miguel Rebollo, Rosa María Benito, Juan Carlos Losada, Javier Galeano</i>	



Resumiendo Opiniones Negativas con Deep Learning y Reglas Descriptivas .....	1017
<i>Ana Valdivia, Eugenio Martínez-Cámara, María Victoria Luzón, Francisco Herrera</i>	
Minería de Opinión no supervisada en Twitter .....	1023
<i>José Ángel Díaz-García, M. Dolores Ruiz, María J. Martín-Bautista</i>	

## V Congreso de la Sociedad Española para las Ciencias del Videojuego (V CoSECiVi)

### CoSECiVi: Sesión 1

Una Plataforma de Integración Continua Especializada en Desarrollo de Videojuegos ..	1033
<i>Iván Martínez-Mateu, Federico Peinado</i>	
Análisis y propuesta de una herramienta basada en gamificación para la educación en valores dentro del deporte .....	1039
<i>Raquel Menéndez Ferreira, Roberto Ruíz Barquín, Antonio Maldonado, David Camacho</i>	
Elicitación de emociones a través del diseño de videojuegos: una revisión del estado del arte .....	1046
<i>Javier Torregrosa, Gema Bello-Orgaz, Raúl Lara-Cabrera, Pei-Chun Shih</i>	
Hacia la personalización de las aventuras culturales .....	1052
<i>Pedro González Calero, María Ángeles Quiroga, Irene Camps, Pedro P. Gómez-Martín</i>	
Retención de Usuarios en Videojuegos de Multijugador Masivo Aplicada al Ámbito Educativo .....	1058
<i>Jorge Osorio, Nahum Álvarez, Federico Peinado</i>	
Game Performance: cuestionamiento del videojuego como pieza cerrada e inalterable ..	1060
<i>Julio M. Álvarez-Bautista</i>	

### CoSECiVi: Sesión 2

Generación Efectiva de Controladores Difusos Evolutivos para Carreras en Simuladores de Coches .....	1067
<i>Antonio Miguel Mora, Salem Mohammed, Juan Julián Merelo, Pablo García Sánchez</i>	
A Machine Learning Approach to Predict the Winner in StarCraft based on Influence Maps .....	1073
<i>Antonio A. Sánchez-Ruiz, Maximiliano Miranda</i>	
Implementación de generador estocástico de partidas mediante la configuración de dimensiones afectivas .....	1075
<i>José Manuel Martínez González, Pablo García Sánchez, Manuel Palomo, Pablo Delatorre</i>	



How a mobile platform for emotion identification supports designing affective games . . . 1081  
*Grzegorz J. Nalepa, Barbara Giżycka*

Desarrollo de un Modelo Estándar de Interacción para Entornos Virtuales . . . . . 1083  
*Juan Luis Berenguel Forte, Francisco Luis Gutiérrez Vela,  
Patricia Paderewski Rodríguez, Daniel Pérez Gázquez*

## II Workshop en Big Data y Análisis de Datos Escalable (II BigDADE)

### BigDADE: Sesión 1

Una primera aproximación para la extracción de patrones emergentes en flujos continuos de datos . . . . . 1093  
*Ángel Miguel García-Vico, Cristóbal José Carmona, Pedro González,  
María José del Jesus*

Segmentación de mercado explicable sobre datos de alta dimensión . . . . . 1099  
*Carlos Eiras Franco, Bertha Guijarro-Berdiñas, Amparo Alonso-Betanzos,  
Antonio Bahamonde*

Bagging-RandomMiner - Un Algoritmo en MapReduce para Detección de Anomalías en Big Data . . . . . 1105  
*Luis Ángel Pereyra Villanueva, Diego García-Gil, Francisco Herrera,  
Luis Carlos González Gurrola, Jacinto Carrasco, Miguel Ángel Medina Pérez,  
Raúl Monroy*

CGLAD: GLAD en problemas de Big Crowdsourced Data . . . . . 1111  
*Enrique González Rodrigo, Juan Ángel Aledo Sánchez, José Antonio Gámez Martín*

Análisis preliminar de marcos tecnológicos en data stream . . . . . 1117  
*Fernando Puentes, María Dolores Pérez-Godoy, Pedro González,  
María José del Jesus*

Selección de características escalable con ReliefF mediante el uso de Hashing Sensible a la Localidad . . . . . 1123  
*Carlos Eiras Franco, Bertha Guijarro-Berdiñas, Amparo Alonso-Betanzos,  
Antonio Bahamonde*

### BigDADE: Sesión 2

Smart Data: Filtrado de Ruido para Big Data . . . . . 1131  
*Diego García-Gil, Julián Luengo, Salvador García, Francisco Herrera*

Un análisis crítico del clasificador AkDE como ensemble y sus implicaciones para tratar con grandes volúmenes de datos . . . . . 1137  
*Jacinto Arias, José Antonio Gámez Martín, José M. Puerta*



Un enfoque aproximado para acelerar el algoritmo de clasificación Fuzzy kNN para Big Data .....	1143
<i>Jesús Maillo, Julián Luengo, Salvador García, Francisco Herrera, Isaac Triguero</i>	
Aplicando la transformada integral de la probabilidad para reducir la complejidad de los árboles de decisión difusos multi-vía en problemas de clasificación Big Data .....	1149
<i>Mikel Elcano, Mikel Uriz, Humberto Bustince, Mikel Galar</i>	
EDGAR-MR: un algoritmo evolutivo distribuido escalable para la obtención de reglas de clasificación .....	1155
<i>Miguel Ángel Rodríguez, Antonio Peregrín</i>	

## I Workshop en Deep Learning (DeepL 2018)

### DeepL: Sesión 1

Optimización de las técnicas de Transfer Learning para la clasificación de la calidad estética en fotografía .....	1165
<i>Fernando Rubio Perona, M. Julia Flores Gallego, José Miguel Puerta Callejón</i>	
Redes Neuronales Convolucionales para Una Clasificación Precisa de Imágenes de Corales .....	1171
<i>Anabel Gómez-Ríos, Siham Tabik, Julián Luengo, Asm Shihavuddin, Bartosz Krawczyk, Francisco Herrera</i>	

### DeepL: Sesión 2

Representaciones basadas en redes neuronales para tareas de recomendación .....	1179
<i>Pablo Pérez-Núñez, Oscar Luaces, Antonio Bahamonde, Jorge Díez</i>	
Una red convolucional para la clasificación de las fases de sueño .....	1185
<i>Isaac Fernández-Varela, Elena Hernández-Pereira, Diego Álvarez-Estevez, Vicente Moret-Bonillo</i>	
Evaluación de estrategias de binarización en la clasificación de imágenes usando deep learning .....	1191
<i>Francisco Pérez Hernández, Siham Tabik, Alberto Castillo Lamas, Hamido Fujita, Francisco Herrera</i>	
Deep Learning for Fake News Classification .....	1197
<i>Miguel Molina-Solana, Julio Amador, Juan Gómez Romero</i>	
Procesamiento, análisis y clasificación de neuroimagen con arquitecturas Deep Learning híbridadas .....	1202
<i>Juan Manuel Górriz Sáez, Andrés Ortiz, Javier Ramirez</i>	



### DeepL: Sesión 3

Guiding the Creation of Deep Learning-based Object Detectors .....	1207
<i>Ángela Casado, Jónathan Heras</i>	
Análisis del impacto de datos desbalanceados en el rendimiento predictivo de redes neuronales convolucionales .....	1213
<i>Francisco Javier Pulgar Rubio, Antonio Jesús Rivera Rivas, Francisco Charte Ojeda, María José del Jesus</i>	
Comparación de marcos de trabajo de Aprendizaje Profundo para la detección de objetos .....	1219
<i>Jesús Benito-Picazo, Karl Thurnhofer-Hemsi, Miguel Ángel Molina-Cabello, Enrique Domínguez-Merino</i>	
Adaptación automática del operador de pooling aprendiendo pesos de medias ponderadas ordenadas en Redes Neuronales Convolucionales .....	1225
<i>Juan I. Forcén, Miguel Pagola, Edurne Barrenechea, Humberto Bustince</i>	
Uso de técnicas de Saliency para Selección de Características .....	1231
<i>Brais Cancela, Verónica Bolón-Canedo, Amparo Alonso-Betanzos, João Gama</i>	

### I Workshop de Grupos de Investigación Españoles de IA en Biomedicina (IABiomed 2018)

#### IABiomed: Sesión 1

IASIS and BigMedilytics: Towards personalized medicine in Europe .....	1241
<i>Ernestina Menasalvas, Alejandro Rodriguez, Consuelo Gonzalo-Martín, Massimiliano Zanin, Juan Manuel Tuñas, Mariano Provencio, María Torrente, Fabio Franco, Virginia Calvo, Beatriz Nuñez</i>	
Tecnologías para el Modelado, Procesamiento y Gestión de Conocimiento .....	1246
<i>Jesualdo Tomás Fernández-Breis, Marcos Menárguez-Tortosa, Catalina Martínez-Costa, Jose Antonio Miñarro Giménez, María Del Carmen Legaz-García, Manuel Quesada-Martínez, Astrid Duque, Ángel Esteban-Gil, Dagoberto Castellanos Nieves</i>	
Resolución de Problemas Biomédicos mediante Técnicas de Extracción de Conocimiento .....	1252
<i>Óscar Reyes, José M. Luna, José M. Moyano, Eduardo Pérez, Sebastián Ventura</i>	
Una aproximación a la interpretación del electrocardiograma desde la perspectiva de la Inteligencia Artificial .....	1258
<i>Paulo Félix Lamas</i>	



## IABiomed: Sesión 2

Hacia un indicador temprano de Deterioro Cognitivo válido como herramienta de screening .....	1267
<i>Rafael Martínez-Tomás, Mariano Rincón Zamorano, Alba Gómez-Valadés, Héctor Gómez Alvarado, Susana Arias Tapia</i>	
eXiT Research Group at the University of Girona: Artificial Intelligence and Machine Learning Applied to Medicine and Healthcare .....	1273
<i>Beatriz López, Natalia Mordvanyuk, Joaquim Massana Raurich, Ferran Torrent-Fontbona, Gerard Cáceres, Carles Pous</i>	
Research on medical decision analysis at the CISIAD, UNED .....	1279
<i>Francisco Javier Díez, Manuel Luque, Jorge Pérez-Martín, Manuel Arias</i>	
Research Group on Artificial Intelligence at Universitat Rovira i Virgili (Tarragona) ....	1285
<i>David Riaño</i>	
Research Topics in Computer-Interpretable Guidelines .....	1289
<i>Mar Marcos, Begoña Martínez-Salvador, Cristina Campos, Reyes Grangel</i>	
Investigación en Inteligencia Artificial en Medicina del grupo AIKE de la Universidad de Murcia .....	1293
<i>Manuel Campos, Bernardo Cánovas-Segura, María A. Cardenas, Felix Gómez-de-León, Fernando Jimenez, José M. Juarez, Roque Marín, Antonio Morales, José T. Palma, Francisco Palacios</i>	

## IV Jornadas de Fusión de la Información y Ensemble Learning (IV FINO)

Measuring Diversity and Accuracy in ANN Ensembles .....	1301
<i>María Paz Sesmero, Juan Manuel Alonso-Weber, Alessandro Giuliani, Giuliano Armano, Araceli Sanchis</i>	
Medidas difusas para la combinación de ensembles: una primera aproximación utilizando el rendimiento en conjuntos de datos altamente desequilibrados .....	1302
<i>Mikel Uriz, Daniel Paternain, Humberto Bustince, Mikel Galar</i>	
Using Ensembles for Improving Fall Detection .....	1308
<i>José Ramón Villar, Enrique de la Cal, Víctor González, Javier Sedano</i>	
NMC: Nearest Matrix Classification - A new combination model for pruning One-vs-One ensembles by transforming the aggregation problem .....	1314
<i>Mikel Galar, Alberto Fernández, Edurne Barrenechea, Humberto Bustince, Francisco Herrera</i>	
A Pareto Based Ensemble with Feature and Instance Selection for Learning from Multi-Class Imbalanced Datasets .....	1316
<i>Alberto Fernández, Cristóbal José Carmona, María José del Jesus, Francisco Herrera</i>	



## **I Workshop en Aplicaciones de la Inteligencia Artificial para la Industria 4.0 (Industria 4.0 2018)**

Academic contributions in supply chain management: A university analysis . . . . .	1321
<i>Keivan Amirbagheri, José M. Merigó, Enrique Herrera-Viedma</i>	
Operadores lingüísticos OWA-RIM para la diagnosis de fallos en plantas complejas . . . .	1327
<i>Álvar Sánchez-Fernández, María Jesús Fuente-Aparicio, Gregorio Ismael Sainz-Palmero, José Manuel Benítez</i>	
Interoperabilidad de flujos de trabajo intensivos en datos en Industria 4.0: caso de estudio	1333
<i>Rubén Salado-Cid, José Molino, José Raúl Romero</i>	
Estimando el tamaño de polímeros con redes neuronales . . . . .	1339
<i>Ekhine Irurozki, José Antonio Lozano</i>	
Evolución del apoyo logístico en la Armada mediante tecnologías 4.0 . . . . .	1345
<i>Francisco Lamas López</i>	

## **Doctoral Consortium**

### **Doctoral Consortium: Sesión 1**

Estrategias y herramientas de apoyo para facilitar la aplicabilidad de los algoritmos bio- inspirados y otras metaheurísticas . . . . .	1355
<i>Mohammed Mahrach, Gara Miranda, Coromoto León</i>	
Combinación de computación evolutiva y aprendizaje automatizado en la resolución de problemas de optimización . . . . .	1361
<i>Alejandro Marrero, Eduardo Segredo, Coromoto León</i>	
Classification system to predicting the psychosocial risk level in public school teachers based on AI . . . . .	1367
<i>Rodolfo Mosquera Navarro, Omar Danilo Castrillon Gómez, Liliana Parra Osorio, Andrés Carrión García</i>	
Una aproximación desde la inteligencia computacional al tratamiento de datos de asegu- radoras y accidentes . . . . .	1373
<i>Ander Carreño</i>	
Big Data Optimization: Framework Algorítmico para el análisis de Datos guiado por Se- mántica . . . . .	1377
<i>Cristóbal Barba-González, José García-Nieto, José F. Aldana Montes</i>	
Paralelización y adaptación de algoritmos de mantenimiento y detección de fallos a pla- taformas de cómputo en la nube . . . . .	1383
<i>Mario Juez-Gil</i>	
Neuroevolución Profunda: Aplicaciones en Ciudades Inteligentes . . . . .	1387
<i>Andrés Camero, Enrique Alba</i>	



On the Study of Crowdsourced Labeled Data and Annotators: Beyond Noisy Labels ...	1393
<i>Iker Beñaran-Muñoz</i>	

### **Doctoral Consortium: Sesión 2**

A study of the influence of fuzzy variables on the economic analysis .....	1399
<i>Javier Bonilla, Javier Montero, J. Tinguaro Rodríguez</i>	

Modelos descriptivos basados en aprendizaje supervisado para el tratamiento de Big Data y flujos continuos de datos .....	1402
<i>Ángel Miguel García-Vico</i>	

A study on the discriminatory capacity of the temporal information on supervised time series classification problems .....	1408
<i>Amaia Abanda, Usue Mori, José Antonio Lozano</i>	

Banca 3.0: Servicios Inteligentes de valor añadido y Salud Financiera. La Banca privada y personalizada para el cliente ya es posible: sinergia entre Inteligencia Artificial, Analítica de Datos, Big Data y Estadística. ....	1413
<i>Javier Porras Castaño</i>	

Deep Neural Networks for Statistical Downscaling of Climate Change Projections .....	1419
<i>Jorge Baño, José Manuel Gutiérrez, Sixto Herrera</i>	

Cost-effective Techniques for Patient Positioning in Percutaneous Radiotherapy Using Optical Imaging Systems .....	1425
<i>Hamid Sarmadi</i>	

Modelo de evaluación de la usabilidad de entornos web basado en las metodologías de computing with words y design thinking. Caso de uso en entornos virtuales de aprendizaje	1429
<i>Noe Zermeño, Rosana Montes, Francisco Herrera</i>	

Modelo Lingüístico Difuso de Evaluación de la Calidad de la Formación Superior en Entornos Metodológicos de Flipped Classroom y M-learning .....	1433
<i>Jeovani Marcos Morales Nieto, Francisco Herrera, Rosana Montes</i>	

Modelo de toma de decisiones lingüística a gran escala aplicado a la evaluación de proyectos de ciencia ciudadana .....	1438
<i>Jerónimo Duran, Rosana Montes, Francisco Herrera</i>	

### **Competición de Apps basadas en Inteligencia Artificial**

Competición CAEPIA-App: MonuMAI: una app para incrementar el valor social del patrimonio-arquitectónico andaluz .....	1445
<i>Francisco Herrera, Álvaro Martínez -Sevilla, Siham Tabik, Rosana Montes, Alberto Castillo Lamas, Teresa Cruz Sánchez, José Policarpo Cruz</i>	

Competición CAEPIA-App: Awesome Pic .....	1449
<i>Fernando Rubio Perona, M. Julia Flores Gallego, José Miguel Puerta Callejón</i>	



Competición CAEPIA-App: senseUMA .....	1453
<i>Jamal Toutouh, Enrique Alba</i>	

**Competición de Vídeos Divulgativos**

Competición Vídeo: ¿Cómo puedo saber si el resultado clustering es lo suficientemente bueno? .....	1459
<i>José María Luna, José C. Riquelme-Santos</i>	

Competición Vídeo: Inteligencia artificial aplicada al desarrollo de software .....	1461
<i>Aurora Ramírez</i>	

Video Competition: Solving Smart Mobility Problems Using Bio-inspired Techniques ..	1464
<i>Daniel H. Stolfi, Enrique Alba</i>	

# Índice de Autores

- Abanda, Amaia **790, 1408**  
Abarca-Álvarez, Francisco Javier **55**  
Acampora, Giovanni **233**  
Agell, Núria **322, 330**  
Aguiló, Isabel **204**  
Alba, Enrique **31, 68, 75, 130, 153, 587, 588, 693, 1387, 1453, 1464**  
Alcalá-Fdez, Jesús **233**  
Alcalde, Cristina **273**  
Aldana Montes, José F. **605, 1377**  
Aledo Sánchez, Juan Ángel **15, 1111**  
Alfaro, Rocío **613**  
Alfaro Jiménez, Juan Carlos **15**  
Alfonso-Robaina, Daniel **324**  
Almansa Aránega, Eva María **573**  
Alonso, Jaime **913**  
Alonso, José María **447, 481**  
Alonso, Pedro **380**  
Alonso, Sergio **365**  
Alonso-Ayuso, Antonio **551**  
Alonso-Betanzos, Amparo **881, 913, 1099, 1123, 1231**  
Alonso-Weber, Juan Manuel **1301**  
Álvarez, Nahum **1058**  
Álvarez-Bautista, Julio M. **1060**  
Álvarez-Estevez, Diego **1185**  
Álvarez-García, Juan A. **944**  
Amador, Julio **1197**  
Amirbagheri, Keivan **424, 1321**  
Andres, Carlos **620**  
de Andrés, Rocío **436, 442**  
Angulo, Cecilio **330**  
Antonucci, Alessandro **13**  
Aragón, Francisco **784**  
Arbelaitz, Olatz **831**  
Arcos, Francisco Jesús **233**  
Arcos-Vargas, Ángel **777**  
Arias, Jacinto **1137**  
Arias, Manuel **1279**  
Arias Tapia, Susana **1267**  
Arjona-Alonso, Ivan **840**  
Armano, Giuliano **1301**  
Armentia, Javier **405**  
Armisen, Albert **330**  
Arnaiz-González, Álar **867, 887**  
Aznar Gimeno, Rocío **80**  
  
De Baets, Bernard **378**  
Bahamonde, Antonio **1099, 1123, 1179**  
Baldán, Francisco Javier **784**  
Baño, Jorge **1419**  
Barba-González, Cristóbal **605, 1377**  
Barbudo, Rafael **157, 593**  
Barón Salazar, Alexander **63**  
Barrenechea, Edurne **239, 1225, 1314**  
Barros, Cristina **465**  
Bartolome Manovel, Mario **41**  
Bautista, Joaquín **613, 614, 626**  
Bejines López, Carlos **369**  
Bello-Orgaz, Gema **995, 1046**  
Bellogín, Alejandro **29**  
Belmonte, Álvaro **931**  
Beñaran-Muñoz, Iker **156, 1393**  
Benítez, José Manuel **573, 784, 1327**  
Benítez Caballero, María José **95**  
Benito, Rosa María **1011**  
Benito-Picazo, Jesús **1219**  
Berenguel Forte, Juan Luis **1083**  
Bermejo, Enrique **510, 706**  
Bernabé-Moreno, Juan **365**  
Bernal de Lázaro, J.M. **849**  
Bielza, Concha **5, 6**



- Bolón-Canedo, Verónica **881, 913, 1231**  
Bonilla, Javier **1399**  
Bugarín, Alberto **335, 469, 481**  
Burgos-Simón, Clara **718**  
Burusco, Ana **273**  
Bustince, Humberto **120, 239, 294, 300, 387, 393, 399, 405, 410, 1149, 1225, 1302, 1314**
- Cabañas de Paz, Rafael **13**  
Cabrera, Inma P. **378**  
Cabrerizo, Francisco Javier **365**  
Cáceres, Gerard **1273**  
de la Cal, Enrique **1308**  
Calvet, Laura **646**  
Calvo, Tomasa **415**  
Calvo, Virginia **1241**  
Camacho, David **995, 1001, 1039**  
Camacho-Cañamón, Julio **167**  
Camero, Andrés **130, 1387**  
Campaña, Jesús R. **989**  
Campomanes-Álvarez, Carmen **510**  
Campos, Cristina **1289**  
de Campos, Luis M. **30**  
Campos, Manuel **173, 832, 1293**  
Campos-Sanchez, Francisco Sergio **55**  
Camps, Irene **1052**  
Cancela, Brais **1231**  
Cano, Andrés **13**  
Cano, José Ramón **891**  
Cánovas-Segura, Bernardo **832, 1293**  
Cantador, Iván **29**  
Cardenas, María A. **1293**  
Cardenas Bonett, Marlon **86, 87**  
Cárdenas Montes, Miguel **129**  
Carmona, Cristóbal José **671, 827, 1093, 1316**  
Carmona, Pablo **293**  
Carmona-Asenjo, Elvira **167**  
Carrasco, Jacinto **855, 1105**  
Carreño, Ander **925, 1373**  
Carrión García, Andrés **1367**  
Casado, Ángela **1207**  
Casanova-Mateo, Carlos **833**  
Casallar Fuentes, Andrea **469**  
Cascon, J. Manuel **436**  
Casillas, Jorge **796**
- Castaño, Alberto **913**  
Castaño, Justo **861**  
Castellanos Nieves, Dagoberto **1246**  
Castellanos-Garzón, José A. **179**  
Castillo, Alberto **145**  
Castillo, Pedro **681**  
Castillo Lamas, Alberto **1191, 1445**  
Castillo Valdivieso, Pedro A **581**  
Castillo-Herrera, Ester **475**  
Castrillon Gómez, Omar Danilo **1367**  
Castro, Juan Luis **293**  
Ceberio, Josu **733, 769**  
Cecilia, José M. **567, 675**  
César, Albusac **30**  
Charte, David **949**  
Charte, Francisco **949**  
Charte Ojeda, Francisco **939, 1213**  
Chasco, María Jesús **369**  
Chávez, Francisco **139, 757**  
Chica, Manuel **503, 614, 626, 987**  
Chica Serrano, Manuel **706**  
Chicano García, José Francisco **31, 68, 588**  
Chinchilla Rodríguez, Zaida **973**  
Ching-López, Alberto **365**  
Cintrano, Christian **31, 588**  
Cobo, Manuel Jesús **967**  
Colmenar, José Manuel **751**  
Contador, Sergio **698**  
Contreras, Ricardo **114**  
Corchado, Juan M. **100, 179**  
Cordero, Pablo **378, 382**  
Córdoba, Irene **5**  
Córdoba Pérez, Franco Esteban **63**  
Cordón, Óscar **503, 510, 614, 626, 706, 712, 961, 987**  
Cornejo, María Eugenia **376**  
Cortés, Juan Carlos **718**  
Cotta, Carlos **518**  
Couso, Inés **359**  
del Coz, Juan José **913**  
Cózar, Javier **259**  
Cruz Corona, Carlos **849**  
Cruz García, Cayetano **512**  
Cruz Sánchez, Teresa **1445**  
Cuadra, Lucas **497**



- Cuenca, Javier **675**  
 Cuesta Calvo, Roberto **840**  
 Čukić, Milena **893**  
 Cutillas Lozano, José Matías **567, 675**  
  
 Damas, Sergio **510, 614, 626, 706**  
 van Deemter, Kees **447**  
 Delatorre, Pablo **1075**  
 Delgado, Miguel **99**  
 Diaz, Irene **380**  
 Díaz Barrancas, Francisco **757**  
 Díaz-García, José Ángel **1023**  
 Díaz-Gómez, Sergio **285**  
 Díaz-Lozano, Miguel **833**  
 Díaz-Moreno, Juan Carlos **324**  
 Díez, Francisco Javier **1279**  
 Díez, Jorge **1179**  
 Díez-Pastor, José Francisco **41, 887**  
 Díez-Pastor, José-Francisco **840**  
 Doallo, Ramón **557**  
 Domínguez Ríos, Miguel Ángel **68**  
 Domínguez-Merino, Enrique **1219**  
 Dorado-Moreno, Manuel **132**  
 Duarte, Abraham **531, 545, 551, 981**  
 Duarte-Martínez, Verónica **967**  
 Duque, Astrid **1246**  
 Duran, Jerónimo **221, 1438**  
 Durán-Rosal, Antonio Manuel **509**  
  
 Eiras Franco, Carlos **1099, 1123**  
 Elkano, Mikel **1149**  
 Elorza, Jorge **369**  
 Enciso, Manuel **382**  
 Espinoza, Sebastián **114**  
 Esteban, Aurora **802**  
 Esteban-Gil, Ángel **1246**  
 Esteva, Francesc **370**  
 Estrada-Moreno, Alejandro **644**  
  
 Fabra-Boluda, Raül **155**  
 Fábregas, José A. **777**  
 Fajardo Contreras, Waldo **99**  
 Fajfar, Andrej **832**  
 Faulin, Javier **641**  
 Félix Lamas, Paulo **1258**  
  
 Fernández, Alberto **1314, 1316**  
 Fernández, Javier **120, 239, 399, 405**  
 Fernández de Vega, Francisco **512, 757**  
 Fernández Díaz, Laura **47**  
 Fernández Díaz, Miriam **47**  
 Fernández Leiva, Antonio José **518**  
 Fernández-Ares, Antonio **581, 681**  
 Fernández-Breis, Jesualdo Tomás **1246**  
 Fernández-Luna, Juan M. **30**  
 Fernández-Olivares, Juan **165**  
 Fernández-Tobías, Ignacio **29**  
 Fernández-Varela, Isaac **1185**  
 Ferrer, Javier **153**  
 Ferri, Cèsar **155, 166**  
 Festa, Paola **527**  
 Flores Gallego, M. Julia **1165, 1449**  
 Forcén, Juan I. **1225**  
 Franco, Fabio **1241**  
 Freixes, Alfons **635, 644**  
 Frutos, Mariano **599**  
 Fuente-Aparicio, María Jesús **231, 253, 1327**  
 Fujita, Hamido **1191**  
 Fuster Parra, Pilar **415**  
  
 Galar, Mikel **294, 1149, 1302, 1314**  
 Galeano, Javier **1011**  
 Galende-Hernández, Marta **231, 253**  
 Gama, João **1231**  
 Gámez Martín, José Antonio **15, 259, 1111, 1137**  
 García, Jesús **35**  
 García, Salvador **855, 891, 919, 949, 1131, 1143**  
 García, Vicente **875**  
 García Arenas, María Isabel **581**  
 García Cabello, Julia **315**  
 García Castillo, Noelia **86**  
 García Castillo, Noelia **87**  
 García Hernández-Díaz, Alfredo **537**  
 García Lapresta, José Luis **227**  
 García Pardo, Eduardo **551**  
 García Sánchez, Pablo **681, 1067, 1075**  
 García-Gil, Diego **1105, 1131**  
 García-González, Jorge **131**  
 García-Gutiérrez, Jorge **821**  
 García-Honrado, Itziar **347**



- García-Nieto, José **605, 1377**  
García-Osorio, César Ignacio **41, 867, 887**  
García-Pardo, Francisca **378**  
García-Ródenas, Ricardo **763**  
García-Vico, Ángel Miguel **671, 1093, 1402**  
Garmendia, Luis **187**  
Garnica, Óscar **698**  
Garrido-Merchán, Eduardo C. **5**  
Gatt, Albert **447**  
Génova, Gonzalo **93**  
Gibaja, Eva **931**  
Gibert, Karina **839**  
Gil-Borrás, Sergio **551**  
Gil-Gala, Francisco **561**  
Gimenez, Domingo **567, 675**  
Giralt-Muiña, Juan **475**  
Giuliani, Alessandro **1301**  
Giżycka, Barbara **1081**  
Godo, Lluís **370**  
Gómez, Daniel **306**  
Gómez, Óscar **712**  
Gómez Alvarado, Héctor **1267**  
Gómez Romero, Juan **53, 79, 1197**  
Gómez-de-León, Felix **1293**  
Gómez-Martín, Pedro P. **1052**  
Gómez-Olmedo, Manuel **13**  
Gómez-Ríos, Anabel **1171**  
Gómez-Sanz, Jorge **86, 87**  
Gómez-Valadés, Alba **1267**  
González, Begoña **599**  
González, Luis D. **901**  
González, Patricia **557**  
González, Pedro **671, 1093, 1117**  
González, Sergio **919**  
González, Víctor **1308**  
González Calero, Pedro **1052**  
González del Campo, Ramón **187**  
González del Pozo, Raquel **227**  
González Gurrola, Luis Carlos **1105**  
González Peñalver, Jesús **681**  
González Rodrigo, Enrique **1111**  
González-Arteaga, Teresa **436, 442**  
González-Gallardo, Sandra **591**  
González-Pardo, Antonio **1001**  
Gonzalo-Martín, Consuelo **1241**  
Gonçalo Oliveira, Hugo **100**  
Górriz Sáez, Juan Manuel **1202**  
Gou, Xunjie **322**  
Grangel, Reyes **1289**  
Guijarro-Berdiñas, Bertha **1099, 1123**  
Guijo-Rubio, David **833**  
Guiote, María-Victoria **167**  
Gutiérrez, José Manuel **1419**  
Gutiérrez, Pedro Antonio **132, 167, 509, 833**  
Gutiérrez Rodríguez, Álvaro **518**  
Gutiérrez Vela, Francisco Luis **1083**  
Gutiérrez-Batista, Karel **989**  
  
Henriques, David **557**  
Heras, Jónathan **1207**  
Hernández, Patricia **512**  
Hernández-González, Jerónimo **154, 156**  
Hernández-Lobato, Daniel **5**  
Hernández-Orallo, José **155**  
Hernández-Pereira, Elena **1185**  
Hernando, Leticia **739**  
Herrera, Francisco **74, 145, 221, 245, 430, 741, 747, 827, 855, 889, 919, 949, 1005, 1017, 1105, 1131, 1143, 1171, 1191, 1314, 1316, 1429, 1433, 1438, 1445**  
Herrera, Sixto **1419**  
Herrera-Viedma, Enrique **315, 365, 1321**  
Hervás-Martínez, César **132, 167, 509, 833**  
Hidalgo, José Ignacio **698, 718, 751**  
Hojas-Mazo, Wenny **279**  
del Hoyo Alonso, Rafael **80**  
Huete, Juan F. **30**  
  
Ibáñez, Óscar **510, 712**  
Iglesias-Rey, Sara **393**  
Imbernón, Baldomero **567, 675**  
Inza, Iñaki **925**  
Irurozki, Ekhine **1339**  
  
del Jesus, María José **671, 815, 827, 939, 949, 1093, 1117, 1213, 1316**  
Jiang, Shouyong **697**  
Jimenez, Fernando **1293**  
Jiménez Zafra, Salud María **955**  
Jiménez-Linares, Luis **475, 487, 763**  
John, Robert **919**



Juan, Ángel	<b>644, 646</b>	Luaces, Oscar	<b>1179</b>
Juan, Ángel A.	<b>635, 641</b>	Luengo, Julián	<b>889, 1131, 1143, 1171</b>
Juarez, José M.	<b>173, 1293</b>	Luis, Nerea	<b>107</b>
Juez-Gil, Mario	<b>867, 1383</b>	Luna, Francisco	<b>665</b>
Junstrand, Axel	<b>893</b>	Luna, José M.	<b>1252</b>
Jurío, Aránzazu	<b>300</b>	Luna, José María	<b>777, 821, 1459</b>
		Luna, José María	<b>815, 907</b>
Kahana, Tzipi	<b>712</b>	Luque, Gabriel	<b>693</b>
Kaiser, Marcus	<b>697</b>	Luque, Javier	<b>587</b>
Krasnogor, Natalio	<b>697</b>	Luque, Manuel	<b>1279</b>
Krawczyk, Bartosz	<b>1171</b>	Luque, Mariano	<b>591, 605</b>
		Luque, Raúl M.	<b>861</b>
Labella, Álvaro	<b>316, 341</b>	Luque-Baena, Rafael Marcos	<b>131, 139</b>
Lafuente, Julio	<b>387</b>	Luzón, María Victoria	<b>1017</b>
Laguna, Manuel	<b>537</b>		
Lamas López, Francisco	<b>1345</b>	Madrid, Nicolás	<b>285</b>
Lamata, María Teresa	<b>423</b>	Madrid, Nicolás	<b>393</b>
Lanchares, Juan	<b>698</b>	Maheut, Julien	<b>620</b>
Lara-Cabrera, Raúl	<b>1046</b>	Mahrach, Mohammed	<b>1355</b>
Larrañaga, Pedro	<b>5</b>	Maillo, Jesús	<b>1143</b>
Larrañaga, Pedro	<b>6</b>	Maldonado, Antonio	<b>1039</b>
LaTorre, Antonio	<b>727, 741, 747</b>	Malleuve-Martínez, Annette	<b>324</b>
Legaz-García, María Del Carmen	<b>1246</b>	Mandow, Lawrence	<b>592</b>
León, Coromoto	<b>1355, 1361</b>	Marco-Detchart, Cédric	<b>120</b>
Lermanda, Tomás	<b>459</b>	Marcos, Mar	<b>1289</b>
Li, Sheng-Tun	<b>919</b>	Marín, Nicolás	<b>453</b>
Lizasoain, Inmaculada	<b>410</b>	Marín, Roque	<b>832, 1293</b>
Llamocca, Pavel	<b>893</b>	Márquez, Antonio Ángel	<b>265</b>
Llanes Santiago, Orestes	<b>849</b>	Márquez, Francisco Alfredo	<b>265</b>
Lloret, Elena	<b>465</b>	Marrero, Alejandro	<b>1361</b>
Lobo, David	<b>376</b>	Martí, Rafael	<b>527</b>
López, Beatriz	<b>1273</b>	Martín Valdivia, María Teresa	<b>955</b>
López, Victoria	<b>893</b>	Martín-Bautista, María J.	<b>53, 989, 1023</b>
López Gómez, Julio Alberto	<b>763</b>	Martín-Moreno, Rodrigo	<b>657</b>
López Liñán, Samuel	<b>573</b>	Martínez, Luis	<b>316, 341</b>
Lopez Martínez-Carrasco, Antonio	<b>173</b>	Martínez, Moisés	<b>107</b>
López-Herrera, Antonio Gabriel	<b>967</b>	Martínez -Sevilla, Álvaro	<b>1445</b>
Lopez-Molina, Carlos	<b>393</b>	Martínez González, José Manuel	<b>1075</b>
López-Nozal, Carlos	<b>867</b>	Martínez-Ballesteros, María	<b>821</b>
López-Rubio, Ezequiel	<b>131</b>	Martínez-Cámara, Eugenio	<b>1005, 1017</b>
López-Sánchez, Ana Dolores	<b>537</b>	Martínez-Costa, Catalina	<b>1246</b>
López-Trigo, Bruno	<b>481</b>	Martínez-Gavara, Anna	<b>527</b>
Losada, Juan Carlos	<b>1011</b>	Martínez-Mateu, Iván	<b>1033</b>
Lozano, Jesús	<b>293</b>	Martínez-Municio, Sergio	<b>475</b>
Lozano, José Antonio	<b>739, 769, 790, 925,</b>	Martínez-Plumed, Fernando	<b>155</b>
	<b>1339, 1408</b>		



- Martínez-Rodríguez, David **718**  
Martínez-Salvador, Begoña **1289**  
Martínez-Tomás, Rafael **1267**  
Mas, Margarita **210**  
Masegosa, Andrés **7**  
Massana Raurich, Joaquim **1273**  
Massanet, Sebastia **198, 216**  
Matínez-Araneda, Claudia **459**  
Maudes, Jesús **840**  
Medina, Jesús **95, 324, 376**  
Medina Pérez, Miguel Ángel **74, 1105**  
Menárguez-Tortosa, Marcos **1246**  
Menasalvas, Ernestina **1241**  
Mencía, Carlos **561**  
Méndez, Máximo **599**  
Méndez-Jiménez, Iván **129**  
Mendiburu, Alexander **739, 769**  
Menéndez, Manuel **231**  
Menéndez Ferreira, Raquel **1039**  
Merelo, Juan Julián **681, 1067**  
Merigó, José M. **424, 1321**  
Merino Gómez, Alejandro **41**  
Mesiar, Radko **239, 387, 410**  
de Miguel, Laura **239, 387, 399, 410**  
Miñarro Giménez, Jose Antonio **1246**  
Minetti, Gabriela **693**  
Miranda, Gara **1355**  
Miranda, Maximiliano **1073**  
Mohammed, Salem **1067**  
Molina, Daniel **727, 741, 747**  
Molina, José Manuel **35**  
Molina-Cabello, Miguel Ángel **131, 1219**  
Molina-Solana, Miguel **53, 79, 99, 1197**  
Molino, José **1333**  
Monroy, Raúl **1105**  
Montañés Rocés, Elena **47**  
Montañés Salas, Rosa **80**  
Monteagudo, Ángel **722**  
Montero, Javier **187, 1399**  
Montes, Rosana **221, 245, 430, 1429, 1433, 1438, 1445**  
Montes, Susana **369, 380**  
Montserrat-Adell, Jordi **322**  
Mora, Antonio Miguel **665, 681**  
Mora, Antonio Miguel **1067**  
Mora Bonilla, Ángel **382**  
Morales, Antonio **173, 1293**  
Morales Nieto, Jeovani Marcos **245, 1433**  
Morán-Fernández, Laura **913**  
Mordvanyuk, Natalia **1273**  
Morell, José Á. **75**  
Moreno Garcia, Juan **487**  
Moreno-Garcia, Antonio **487**  
Moret-Bonillo, Vicente **1185**  
Mori, Usue **790, 1408**  
Morillo-Salas, José Luis **881**  
Mosquera Navarro, Rodolfo **1367**  
Moya, Ignacio **503, 614, 987**  
Moyano, José M. **861, 907, 1252**  
Mozos, José M. **635, 641**  
Muguerza, Javier **831**  
  
Nalepa, Grzegorz J. **1081**  
Napoletano, Antonio **527**  
Navarro-Cáceres, María **100**  
Nebro, Antonio J. **605**  
Nguyen, Jennifer **330**  
Nuñez, Beatriz **1241**  
  
Ochoa, Gustavo **410**  
Ojeda-Aciego, Manuel **378**  
Olivas, José Ángel **279, 353**  
Olmos, Roberto **145**  
Ortega, Alfonso **995**  
Ortega, Julio **681**  
Ortiz, Andrés **1202**  
Ortiz-De-Lazcano-Lobato, Juan M. **131**  
Osorio, Jorge **1058**  
Ospina, Carlos **641**  
de la Ossa, Luis **259**  
  
Paderewski Rodríguez, Patricia **1083**  
Padilla, Pablo **665**  
Pagés-Bernaus, Adela **646**  
Pagola, Miguel **1225**  
Palacios, Francisco **173, 832, 1293**  
Palma, José T. **1293**  
Palomo, Manuel **1075**  
Panadero, Javier **635, 641, 644**  
Panizo Lledot, Ángel **995**  
Parra, Manuel **784**



- Parra Osorio, Liliana **1367**  
Pastore, Tommaso **527**  
Paternain, Daniel **294, 410, 1302**  
Pavon, Juan **86**  
de Paz, Juan Francisco **179**  
Peinado, Federico **1033, 1058**  
Pelta, David **423, 697**  
Peña Larena, Paula **80**  
Peregrín, Antonio **265, 1155**  
Pereyra Villanueva, Luis Ángel **1105**  
Pérez, Aritz **156, 733**  
Pérez, Carlos J. **651**  
Pérez, Eduardo **901, 1252**  
Pérez, Francisco **145**  
Pérez, Raul **165**  
Pérez de la Cruz, José-Luis **592**  
Pérez Gázquez, Daniel **1083**  
Pérez Hernández, Francisco **1191**  
Pérez-Godoy, María Dolores **1117**  
Pérez-Martín, Jorge **1279**  
Pérez-Núñez, Pablo **1179**  
Pérez-Peló, Sergio **531, 981**  
Perianes-Rodríguez, Antonio **973**  
Perona, Iñigo **831**  
Pineda Torres, Ivo H. **808**  
Pinninghoff, María Angélica **114**  
Plaza, Francisco **775**  
Plaza del Arco, Flor Miriam **955**  
Policarpo Cruz, José **1445**  
Polvillo-Hall, Alejandro **944**  
Porcel, Carlos **365**  
Porras Castaño, Javier **1413**  
Pous, Carles **1273**  
Pradera, Ana **216**  
Prati, Ronaldo **889**  
Prieto, Luis **132**  
Prieto-Moreno, Alberto **849**  
Provencio, Mariano **1241**  
Puentes, Fernando **1117**  
Puerta, José M. **1137**  
Puerta Callejón, José Miguel **1165, 1449**  
Puerto-Santana, Carlos **6**  
Pulgar Rubio, Francisco Javier **1213**  
  
Quesada-Martínez, Manuel **1246**  
  
Quevedo Pérez, José Ramón **47**  
Quintana, Juan David **545**  
Quintanilla Navarro, Ignacio **93**  
Quiroga, María Ángeles **1052**  
  
R Banga, Julio **557**  
Ramalinho, Helena **646**  
Ramírez, Aurora **593, 1461**  
Ramirez, Javier **1202**  
Ramírez Poussa, Eloisa **95**  
Ramírez-Quintana, María José **155, 166**  
Ramos, Juan **179**  
Ramos Soto, Alejandro **447, 469**  
Rand, William **503**  
Rebollo, Miguel **1011**  
Recasens, Jordi **192**  
Reiter, Ehud **447**  
Revelo Sánchez, Óscar **63**  
Rey, Isabel **253**  
Reyes, Óscar **861, 901, 907, 1252**  
Reyes Pupo, Óscar **815**  
Reyes-Rubiano, Lorena Silvana **641**  
Riaño, David **1285**  
Riera, Juan Vicente **198**  
Riesgo, Ángel **380**  
Rincón Zamorano, Mariano **1267**  
Riquelme-Santos, José C. **777, 821, 1459**  
Rivas-Gervilla, Gustavo **453**  
Rivera Rivas, Antonio Jesús **939, 1213**  
Rivero, Antonio **861**  
Rivero-Juárez, Antonio **861**  
Rodríguez, Alejandro **1241**  
Rodríguez, Iosu **405**  
Rodríguez, J. Tinguaro **306, 1399**  
Rodríguez, Juan J. **887**  
Rodríguez, Miguel Ángel **1155**  
Rodríguez, Rosa M. **316, 341**  
Rodríguez Díaz, Francisco Javier **139**  
Rodríguez Penas, David **557**  
Rodríguez Puerta, Borja **139, 757**  
Rodríguez Serrano, Francisco José **573**  
Rodríguez-Benítez, Luis **475, 487**  
Rodríguez-Cáceres, Ester **167**  
Roldán, Ana María **265**  
Roldán, Antonio **387**



- Romero, Cristóbal **802**  
Romero, José Raúl **157, 593, 1333**  
Romero Chicharro, Francisco P. **279, 353**  
Romero Gómez, Luis Felipe **74**  
Ros, María **53**  
Rossainz-Lopez, Mario **808**  
Rossit, Daniel Alejandro **599**  
del Rosso Calache, Lucas Daniel **430**  
Rovira, Xari **330**  
Rubio Manzano, Clemente **324, 459**  
Rubio Perona, Fernando **1165, 1449**  
Rubio-Escudero, Cristina **944**  
Ruiz, Ana B. **591, 605**  
Ruiz, Elena **796**  
Ruiz, M. Dolores **53, 1023**  
Ruíz Barquín, Roberto **1039**  
Ruiz Morilla, José **353**  
Ruiz-Aguilera, Daniel **210, 216**  
Ruiz-Aranguren, Javier **405**
- Saborido, Rubén **591**  
Sáez-Lozano, José L. **987**  
Sáez-Rodríguez, Julio **557**  
Sainz-Palmero, Gregorio Ismael **231, 253, 1327**  
Salado-Cid, Rubén **1333**  
Salas, Rodrigo **775**  
Salcedo-Sanz, Sancho **132, 497, 509, 706, 833**  
Salmerón, Antonio **7**  
Salto, Carolina **693**  
Sánchez, Daniel **453**  
Sánchez, J. Salvador **875**  
Sánchez, Luciano **359**  
Sánchez, Luis M. **901**  
Sanchez Fernandez, Andrés Jesús **74**  
Sánchez-Fernández, Álgar **1327**  
Sánchez-Gómez, Jesús M. **651**  
Sánchez-Hernández, Germán **330**  
Sánchez-Marrè, Miquel **839**  
Sánchez-Oro, Jesús **531, 537, 545, 981**  
Sánchez-Ruiz, Antonio A. **1073**  
Sanchis, Araceli **1301**  
Santamaría-Colula, Luis Ángel **808**  
Santander-Jiménez, Sergio **687**  
Santos, José **722**  
Santos-Bueno, Antonio-María **167**  
Sanz Delgado, José Antonio **399**  
Sarmadi, Hamid **1425**  
Sedano, Javier **1308**  
Segredo, Eduardo **1361**  
Segura Muros, José Á. **165**  
Segura-Navarrete, Alejandra **459**  
Seoane-Martínez, Rubén **881**  
Serrano-Guerrero, Jesús **353**  
Serrat, Carles **644**  
Sesma-Sara, Mikel **239, 387, 399**  
Sesmero, María Paz **1301**  
Sevilla-Villanueva, Beatriz **839**  
Shih, Pei-Chun **1046**  
Shihavuddin, Asm **1171**  
Sierra, María R. **561**  
da Silva Neto, Antônio José **849**  
Silva Palacios, Daniel Andrés **166**  
Simón-Cuevas, Alfredo **279**  
Sittón-Candanedo, Inés **21**  
Slezak, Dominik **95**  
Sobrino Cerdeiriña, Alejandro **335**  
Somodevilla, María J. **808**  
Soto-Hidalgo, José Manuel **233**  
Sousa, Leonel **687**  
Stiglic, Gregor **832**  
Stolfi, Daniel H. **31, 1464**  
Stütze, Thomas **588**  
Suárez, José Ignacio **293**  
Suñer, Jaume **204**
- Tabik, Siham **74, 145, 1005, 1171, 1191, 1445**  
Tejeda-Lorente, Álvaro **365**  
Tejedor, Javier **777**  
Thurnhofer-Hemsi, Karl **1219**  
Tomás, María Santos **192**  
Tomeo, Paolo **29**  
Torra, Vicenc **300**  
Torregrosa, Javier **1046**  
Torrens, Joan **198, 204, 210, 216**  
Torrent-Fontbona, Ferran **1273**  
Torrente, María **1241**  
Torres, Antonio **7**  
Torres, Marina **697**  
Toutouh, Jamal **130, 587, 1453**



Triguero, Isaac	1143	Vidal-Castro, Christian	459
Trujillo Viedma, Daniel	939	Vila, María-Amparo	989
Tuñas, Juan Manuel	1241	Villalobos, Ignacio	153
Ureña López, Luis Alfonso	955	Villanueva, Rafael	718
Urgelés, Diego	893	Villar, José Ramón	1308
Uriz, Mikel	294, 1149, 1302	Villarino, Guillermo	306
Valdivia, Ana	1005, 1017	Vitiello, Autilia	233
Valenzuela-Valdés, Juan F.	665	Vychodil, Vilem	382
Valero, Óscar	415	Xu, Zeshui	322
Vallejo-Casas, Juan-Antonio	167	Yáñez, Eleuterio	775
Valsecchi, Andrea	510, 712	Yera, Ainhoa	831
Varela, Ramiro	561	Zafra, Amelia	802, 931
Vargas-Quesada, Benjamín	973	Zanin, Massimiliano	1241
Vega-Rodríguez, Miguel A.	651, 657, 687	Zapata, Pablo	665
Velasco, J. Manuel	698	Zarco, Carmen	961
Velasco Benito, Gael	335	Zermeño, Noe	430, 1429
Ventura, Sebastián	157, 593, 815, 861, 901, 907, 931, 1252	Zuheros, Cristina	1005
Verdegay, José Luis	423	Zúñiga Herrera, Sarahi	808
Vicente, Marta	465		
Vidal Wandelmer, Amanda	370		

**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

SESIÓN GENERAL

FRANCISCO HERRERA

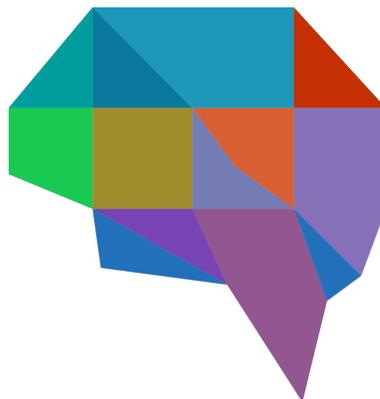
SERGIO DAMAS





**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 1:  
MODELOS GRÁFICOS  
PROBABILÍSTICOS Y  
ÁRBOLES DE DECISIÓN







# Bayesian optimization of the PC algorithm for learning Gaussian Bayesian networks\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Irene Córdoba

*Departamento de Inteligencia Artificial*  
*Universidad Politécnica de Madrid*  
Madrid, Spain  
irene.cordoba@upm.es

Eduardo C. Garrido-Merchán

*Departamento de Ingeniería Informática*  
*Universidad Autónoma de Madrid*  
Madrid, Spain  
eduardo.garrido@uam.es

Daniel Hernández-Lobato

*Departamento de Ingeniería Informática*  
*Universidad Autónoma de Madrid*  
Madrid, Spain  
daniel.hernandez@uam.es

Concha Bielza

*Departamento de Inteligencia Artificial*  
*Universidad Politécnica de Madrid*  
Madrid, Spain  
mcbielza@fi.upm.es

Pedro Larrañaga

*Departamento de Inteligencia Artificial*  
*Universidad Politécnica de Madrid*  
Madrid, Spain  
plarranaga@fi.upm.es

**Abstract**—The PC algorithm is a popular method for learning the structure of Gaussian Bayesian networks. It carries out statistical tests to determine absent edges in the network. It is hence governed by two parameters: (i) The type of test, and (ii) its significance level. These parameters are usually set to values recommended by an expert. Nevertheless, such an approach can suffer from human bias, leading to suboptimal reconstruction results. In this paper we consider a more principled approach for choosing these parameters in an automatic way. For this we optimize a reconstruction score evaluated on a set of different Gaussian Bayesian networks. This objective is expensive to evaluate and lacks a closed-form expression, which means that Bayesian optimization (BO) is a natural choice. BO methods use a model to guide the search and are hence able to exploit smoothness properties of the objective surface. We show that the parameters found by a BO method outperform those found by a random search strategy and the expert recommendation. Importantly, we have found that an often overlooked statistical test provides the best over-all reconstruction results.

**Index Terms**—



# Asymmetric Hidden Markov Models with Continuous Variables\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Carlos Puerto-Santana  
*Technical University of Madrid*  
Madrid, Spain  
ce.puerto@alumnos.upm.es

Concha Bielza  
*Technical University of Madrid*  
Madrid, Spain  
mcbielza@fi.upm.es

Pedro Larrañaga  
*Technical University of Madrid*  
Madrid, Spain  
pedro.larranaga@fi.upm.es

**Abstract**—Hidden Markov models have been successfully applied to model signals and dynamic data. However, when dealing with many variables, traditional hidden Markov models do not take into account asymmetric dependencies, leading to models with overfitting and poor problem insight. To deal with the previous problem, asymmetric hidden Markov models were recently proposed, whose emission probabilities are modified to follow a state-dependent graphical model. However, only discrete models have been developed. In this paper we introduce asymmetric hidden Markov models with continuous variables using state-dependent linear Gaussian Bayesian networks. We propose a parameter and structure learning algorithm for this new model. We run experiments with real data from bearing vibration. Since vibrational data is continuous, with the proposed model we can avoid any variable discretization step and perform learning and inference in an asymmetric information frame.

**Index Terms**—Hidden Markov models, Bayesian networks, Model selection, Structure learning, Time series, Information Asymmetries, Linear Gaussian Bayesian Network



# Un test de dos muestras multinomiales basado en modelos Bayesianos jerárquicos

Antonio Torres  
Departamento de matemáticas  
Universidad de Almería  
Almería, España  
atr159@ual.es

Andrés Masegosa  
Departamento de matemáticas  
Universidad de Almería  
Almería, España  
andresmasegosa@ual.es

Antonio Salmerón  
Departamento de matemáticas  
Universidad de Almería  
Almería, España  
antonio.salmeron@ual.es

**Resumen**—Decidir si dos muestras pertenecen o no a la misma distribución es un problema que aparece en muchas ramas de la ciencia y de la industria. La herramienta más usada para este problema es un contraste de hipótesis basado en el test Chi-cuadrado. El resultado de este procedimiento depende del llamado p-valor. El problema de este p-valor es que no recoge la incertidumbre asociada al tamaño de las muestras. Es decir, el proceso de decisión de si dos muestras multinomiales son o no iguales es el mismo tanto para tamaños muestrales pequeños como para tamaños muestrales muy grandes. En este trabajo presentamos una metodología Bayesiana que es muy fácil de implementar. En este caso devolvemos una distribución *a posteriori* sobre un índice de diferencia entre dos distribuciones. Al ser un esquema Bayesiano podemos cuantificar la incertidumbre en la que se basan nuestras decisiones, y como consecuencia más directa, podemos determinar si el tamaño de las muestras es suficientemente grande como para tomar decisiones robustas acerca de si dos muestras multinomiales pertenecen o no a la misma distribución.

**Index Terms**—Test de dos muestras, Test Chi-cuadrado, Test Bayesiano.

## I. INTRODUCCIÓN

Los test de dos muestras (*two-sample tests*) son muy útiles tanto en industria como en ciencia. Estos se basan en comparar si dos conjuntos de datos están generados por la misma distribución o no [5]. Para el caso de la industria nos encontramos, por ejemplo, con los test A/B [4], que nos sirven para comparar dos versiones de un mismo diseño para ver cuál de los dos se comporta estadísticamente mejor. Ejemplos de esto podemos encontrarlos en las empresas que envían distintas versiones de un correo a diferentes destinatarios, o en la web, donde aparecen varias versiones de la misma página para los distintos visitantes [4]. En el caso de la ciencia, un claro ejemplo son los ensayos clínicos, en los que se dispone de dos grupos de individuos con una cierta enfermedad o accidente donde a uno de ellos se le administra un determinado tratamiento (grupo experimental) y el otro grupo (grupo de control) al que o bien no se le administra ningún tratamiento o bien se le administra otro en fase de pruebas y es comparado con el experimental con el objetivo de sacar conclusiones acerca de los tratamientos utilizados [1].

Mediante los test de hipótesis Chi-cuadrado podemos comparar si el conjunto de datos proviene o no de una misma distribución a través de una hipótesis nula y otra alternativa. En

este caso, esto se mediría con el p-valor, que pasado de cierto umbral prefijado hace que se rechace o acepte la hipótesis nula. Sin embargo, el p-valor no mide la incertidumbre debido principalmente al tamaño de la muestra. Entonces nos surge la pregunta: ¿cuál es el tamaño de muestra necesario para estar seguros de que las conclusiones obtenidas en el test de hipótesis no dependen de dicho tamaño? El test Chi-cuadrado (y otros test frecuentistas) no puede dar respuesta a esta pregunta [3].

En este trabajo proponemos un método alternativo basado en estadística Bayesiana. Este método no da respuestas binarias como hace el test Chi-cuadrado o los test frecuentistas (se acepta o no se acepta la hipótesis nula) debido a que nos proporcionan una probabilidad a posteriori de que sea o no cierta la hipótesis nula, donde la incertidumbre se va reduciendo según se aumenta el tamaño de la muestra [2]. Este test se basa en una técnica llamada *a priori jerárquicas de potencia*, o en inglés *Hierarchical Power Priors* (HPP) [2].

## II. CONOCIMIENTOS PREVIOS

En muchos problemas de inferencia Bayesiana no podemos calcular la distribución a posteriori directamente debido a que la constante de normalización no se puede calcular. Por ejemplo, sea  $x$  un conjunto de observaciones, y  $p$  un conjunto de variables latentes, si queremos calcular la distribución a posteriori  $P(p|x)$ , que sabemos que  $P(p|x) = \frac{P(x|p)P(p)}{\int P(x|p)P(p)dp}$ , en algunas ocasiones no podremos calcular el denominador, bien porque la dimensión sea muy grande o bien porque la integral tiene una expresión muy compleja. Para resolver esto se utiliza la estadística bayesiana, donde se define una  $q(p|\omega)$  lo más cercana posible a  $P(p|x)$  en distancia de Kullback-Leibler, esto es, buscamos  $\arg \min_{\omega} \text{KL}(q(p|\omega), P(p|x))$ .

Es decir, cuando intentamos calcular esta probabilidad a posteriori lo que se hace es buscar una distribución que sea lo más cercana posible a esta, en términos de la distancia de Kullback-Leibler. Una vez hecho esto, se buscan los parámetros de la distribución  $q(p|\omega)$  que mejor aproxima a la a posteriori verdadera  $P(p|x)$ .

## III. A PRIORIS JERÁRQUICAS DE POTENCIA

El modelo HPP [2] es un modelo probabilístico generativo que permite modelar cambios en los parámetros de una dis-

tribución. En la Fig. 1 podemos ver una descripción gráfica de este modelo y, por otro lado, el Algoritmo 1 nos muestra una descripción en pseudocódigo de este método: (1) en el primer paso,  $p_0$  se muestrea de una distribución Dirichlet de hiper-parámetros  $\alpha_u = (1, \dots, 1)$ , (2) en el segundo paso, se generan los datos de la primera muestra en base al parámetro  $p_0$  previamente generado, (3) en el tercer paso se calcula la distribución a posteriori de  $p_0$  dados los datos muestreados, que también sigue una distribución Dirichlet, donde  $\alpha_0$  son los parámetros de la distribución a posteriori de  $p_0$ , (4) en el cuarto paso, muestreamos  $\rho$  a partir de una distribución exponencial truncada en el intervalo  $[0, 1]$  y de parámetro fijo  $\gamma = 0.1$ , (5) en un quinto paso, se muestrea el parámetro  $p_1$  a partir de una Dirichlet con parámetro  $\rho\alpha_0 + (1 - \rho)\alpha_u$ , (6) y, por último, en el sexto paso se muestrea  $x_1$  en base a una multinomial de parámetro  $p_1$ .

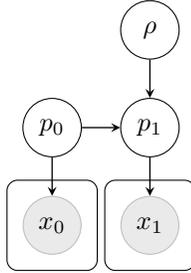


Figura 1: Modelo HPP.

---

**Algoritmo 1** Modelo HPP.

- 1:  $p_0 \sim \text{Dir}(1, \dots, 1) \equiv \text{Dir}(\alpha_u)$
  - 2:  $x_0 \sim \text{Multinom}(p_0)$
  - 3:  $\text{Dir}(\alpha_0) = P(p_0|x_0)$
  - 4:  $\rho \sim \text{TruncExp}_{[0,1]}(\gamma)$
  - 5:  $p_1 \sim \text{Dir}(\rho\alpha_0 + (1 - \rho)\alpha_u)$
  - 6:  $x_1 \sim \text{Multinom}(p_1)$
- 

En este modelo generativo de los datos, la variable  $\rho$  es la que define la transición entre los parámetros  $p_0$  y  $p_1$  que generan los datos,  $p(p_1|p_0, \rho)$ , de forma que la distribución a posteriori de  $p_1$  dado  $x_0$  se calcularía como:

$$p(p_1|x_0, \rho) = \int p(p_1|p_0, \rho)p(p_0|x_0)dp_0.$$

El problema es que para el caso de una distribución Dirichlet condicionada a otra distribución Dirichlet, como sucede en este caso para datos multinomiales, daría lugar a un modelo no-conjugado, lo que complica el cálculo de la distribución a posteriori. El modelo HPP define esta probabilidad de transición de manera implícita [2] bajo principios de máxima entropía. El resultado es un modelo de transición con las siguientes propiedades:

- Si  $\rho = 0$ , entonces  $p(p_1|p_0, \rho = 0) = p(p_1|\alpha_u)$  y, denotamos  $p(p_1|x_0, \rho = 0)$  como  $p_u(p_1)$ . Es decir, no existe relación entre  $p_0$  y  $p_1$ .
- Si  $\rho = 1$ , entonces  $p(p_1|p_0, \rho = 1) = \delta(p_1 - p_0)$  y, denotamos  $p(p_1|x_0, \rho = 1)$  como  $p_\delta(p_1|x_0)$ . Es decir,

existe una relación determinística de igualdad entre ambos,  $p_0 = p_1$ .

- Si  $0 < \rho < 1$ , entonces

$$p(p_1|x_0, \rho) \propto p_\delta(p_1|x_0)^\rho p_u(p_1)^{(1-\rho)},$$

es decir, es una mezcla de las dos situaciones extremas anteriores. En el caso de la distribución Dirichlet, esa operación se simplifica como la combinación convexa de sus hiper-parámetros [2].

El modelo HPP nos permite aplicar inferencia variacional para calcular la distribución a posteriori del parámetro  $\rho$  dados los datos, es decir,  $p(\rho|x_0, x_1)$ , siguiendo el Algoritmo 2. Siguiendo el método variacional, esta probabilidad a posteriori es aproximada por una distribución exponencial truncada,  $q(\rho|\omega)$ .

Como se ha comentado con anterioridad,  $\rho$  toma valores en  $[0, 1]$ . Si  $\rho = 0$  significa que el cambio es absoluto, y por el contrario, si  $\rho = 1$ , entonces no hay cambio. La probabilidad a posteriori es la que nos da información sobre este cambio. Esto no se trata de un test estadístico, sino que es una cuestión de interpretación. Por otro lado, comentar que  $\omega$  es el parámetro de la exponencial truncada que aproxima a la a posteriori.

La función de densidad,  $q(\rho|\omega)$ , así como el valor esperado,  $E_\omega[\rho]$ , y la varianza,  $\text{Var}_\omega[\rho]$ , se calculan de la siguiente manera:

$$q(\rho|\omega) = \frac{\gamma e^{\gamma\rho}}{1 - e^{-\gamma}}, \quad (1)$$

$$E_\omega[\rho] = \frac{1}{1 - e^{-\omega}} - \frac{1}{\omega}, \quad (2)$$

$$\text{Var}_\omega[\rho] = \frac{1 + e^{2\omega} - e^\omega(2 + \omega^2)}{(e^\omega - 1)^2\omega^2}. \quad (3)$$

Además denotamos  $\text{KL}(\lambda, \lambda')$  como la distancia de Kullback-Leibler entre dos distribuciones Dirichlet con parámetros  $\lambda$  y  $\lambda'$ , que se puede expresar como

$$\begin{aligned} \text{KL}(\lambda, \lambda') &= \sum [(\lambda - \lambda')(\psi(\lambda) - \psi(\lambda_0))] \\ &+ \sum [\ln \Gamma(\lambda') - \ln \Gamma(\lambda)] \\ &+ \ln \Gamma(\lambda_0) - \ln \Gamma(\lambda'_0), \end{aligned} \quad (4)$$

siendo  $\psi(x) = \frac{d}{dx} \ln \Gamma(x) = \frac{\Gamma'(x)}{\Gamma(x)}$  la conocida función *digamma*,  $\lambda_0 = \sum \lambda$  y  $\lambda'_0 = \sum \lambda'$ .

---

**Algoritmo 2** Calcular  $q(\rho|\omega) \approx p(\rho|x_0, x_1)$ .

**Entrada:**  $(x_0, x_1)$

**Salida:**  $p(\rho|\omega)$

1:  $\lambda_u = (1, \dots, 1)$

2:  $\lambda_1 = x_0 + \lambda_u$

3:  $\lambda_2 = x_1 + \lambda_1$

4: **Repetir**

5:  $\omega = \text{KL}(\lambda_2, \lambda_u) - \text{KL}(\lambda_2, \lambda_1) + \gamma$

6:  $\lambda_2 = x_1 + E_\omega[\rho]\lambda_1 + (1 - E_\omega[\rho])\lambda_u$

7: **hasta** convergencia

8: **return**  $q(\rho|\omega)$

---



IV. EXPERIMENTOS

En esta sección vamos a ver una serie de experimentos (realizados en R) con el objetivo de comparar las diferencias entre usar el método Chi-cuadrado, y el modelo HPP. Para ello vamos a analizar cómo varían por un lado los p-valores, y por otro, la salida del modelo HPP. Para llevar esto a cabo, consideraremos una distribución multinomial  $p_0$ , muestrearemos y obtenemos una muestra  $x_0$ , donde el tamaño muestral irá variando. Con el mismo tamaño de la muestra, consideramos también una distribución  $p_1$ , muestreamos y obtenemos otra muestra  $x_1$ . Hecho esto es cuando aplicamos ambos test de hipótesis y comparamos los resultados. Este experimento lo repetiremos para diferentes tamaños de muestra (de menor a mayor). A su vez para cada tamaño muestral, muestrearemos un total de 1000 veces las muestras  $x_0$  y  $x_1$  y daremos un diagrama de cajas mostrando los resultados.

Como hemos dicho, el test Chi-cuadrado da como respuesta un valor, el p-valor, mientras que el método HPP da como respuesta una probabilidad a posteriori  $p(\rho|x_0, x_1)$ . Con el fin de comparar ambos, de la salida del método HPP mostraremos los siguientes valores: el *máximo a posteriori* (MAP) de  $\rho$ ,  $\arg \max_{\rho} p(\rho|x_0, x_1)$ ; el valor esperado de  $\rho$ ,  $E_{\omega}[\rho]$ ; y la varianza de  $\rho$ ,  $\text{Var}_{\omega}[\rho]$ .

IV-A. Comparación de  $q(\rho|\omega)$  y P-valores para dos probabilidades  $p_0$  y  $p_1$  iguales cuando aumenta el tamaño muestral.

En este caso consideramos que ambas distribuciones son iguales con  $p_0 = p_1 = (0.5, 0.2, 0.1, 0.1, 0.1)^T$ . De este experimento extraemos las siguientes conclusiones:

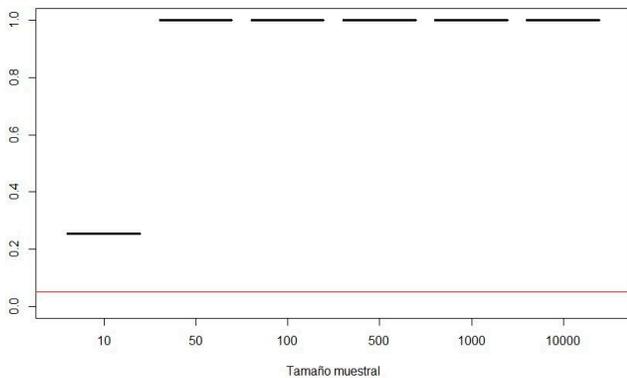


Figura 2: P-valor para dos distribuciones iguales cuando aumenta el tamaño muestral. La línea roja horizontal muestra el p-valor 0.05.

- Comenzaremos viendo qué ocurre con el p-valor. En la Fig. 2 podemos ver la representación gráfica de éstos según aumenta el tamaño muestral. Como puede verse con 10 muestras sale un p-valor menor que con el resto de muestras, pero aún así son valores suficientemente altos como para aceptar la hipótesis nula de igualdad entre las dos distribuciones al 95 % de confianza (es decir, con un nivel de significación de 0.05).
- En segundo lugar, representamos gráficamente el MAP de  $\rho$  en la Fig. 3. Como puede verse, la representación del

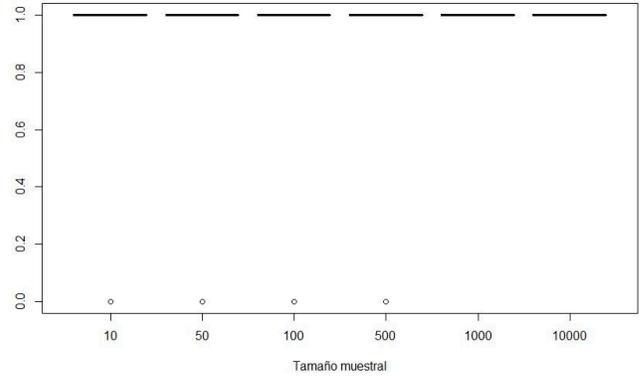


Figura 3: MAP para dos distribuciones iguales cuando aumenta el tamaño muestral.

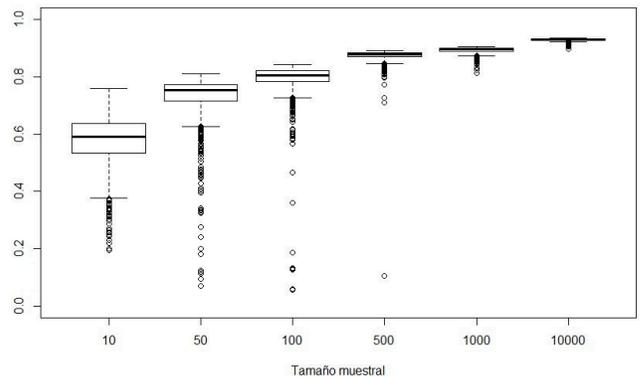


Figura 4:  $E_{\omega}[\rho]$  para dos distribuciones iguales cuando aumenta el tamaño muestral.

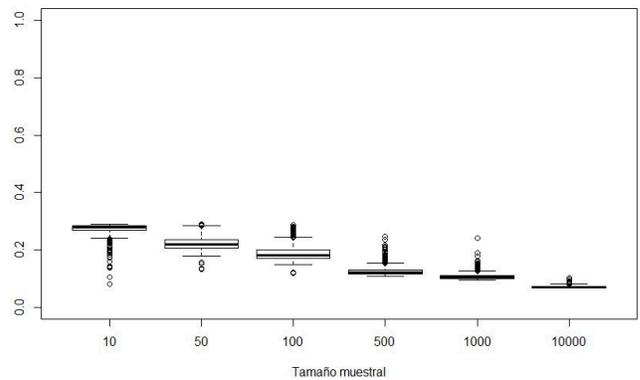


Figura 5:  $\text{Var}_{\omega}[\rho]$  para dos distribuciones iguales cuando aumenta el tamaño muestral.

MAP coincide bastante con la de los p-valores obtenidos mediante el método chi cuadrado. En este caso sin embargo, disponemos de una probabilidad a posteriori que nos permite saber también el valor esperado para  $\rho$ .

- En la Fig. 4 vemos la representación para  $E_{\omega}[\rho]$  como comentábamos en el punto anterior. En esta imagen, y a diferencia de los p-valores, podemos ver que ésta va aumentando según aumenta el número de muestras y la variabilidad de la misma se va haciendo cada vez más pequeña, y por ello, más precisa. Esta precisión también puede verse a través de la varianza.
- En la Fig. 5 tenemos la representación gráfica de  $\text{Var}_{\omega}[\rho]$ . En esta puede apreciarse como la varianza se va reduciendo conforme aumenta el número de muestras, pudiendo comprobarse que, efectivamente, la incertidumbre se reduce según se aumenta el tamaño de la muestra.

#### IV-B. Comparación de $q(\rho|\omega)$ y P-valores para dos probabilidades $p_0$ y $p_1$ distintas cuando aumenta el tamaño muestral.

En este segundo experimento consideraremos que las dos distribuciones son diferentes con  $p_0$  la misma que en el caso anterior y  $p_1 = (0.1, 0.2, 0.5, 0.1, 0.1)$ . De este experimento extraemos las siguientes conclusiones:

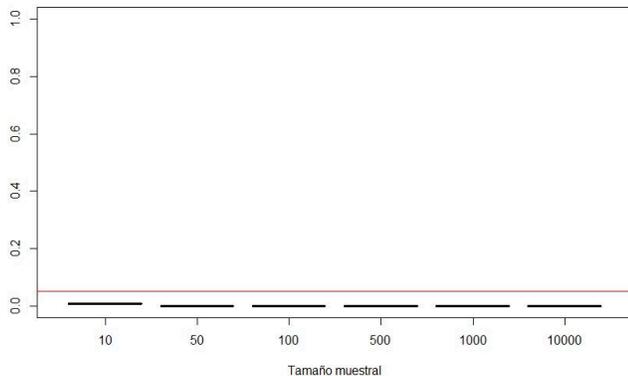


Figura 6: P-valor para dos distribuciones distintas cuando aumenta el tamaño muestral. La línea roja horizontal muestra el p-valor 0.05.

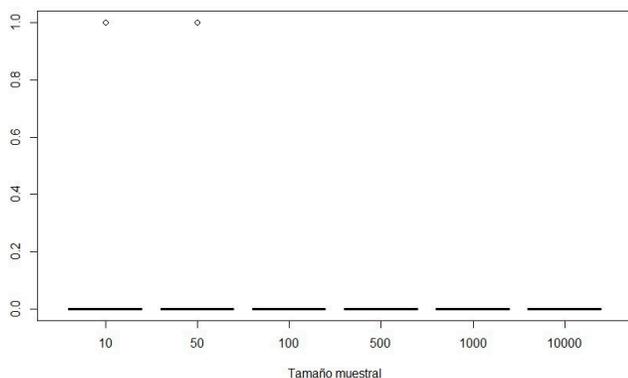


Figura 7: MAP para dos distribuciones distintas cuando aumenta el tamaño muestral.

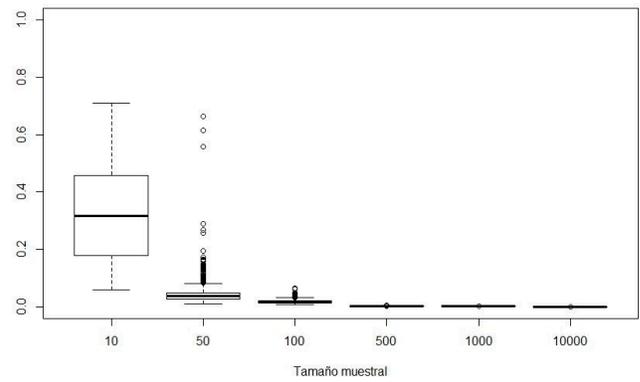


Figura 8:  $E_{\omega}[\rho]$  para dos distribuciones distintas cuando aumenta el tamaño muestral.

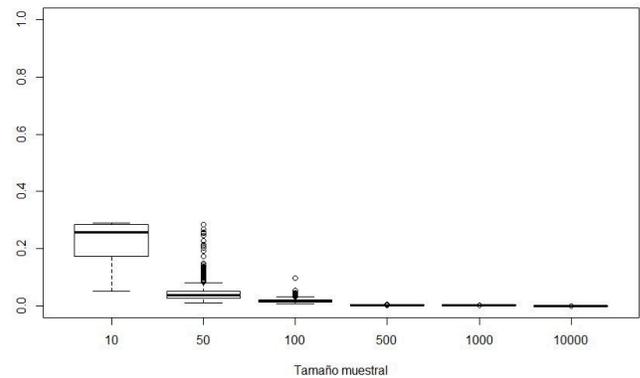


Figura 9:  $\text{Var}_{\omega}[\rho]$  para dos distribuciones distintas cuando aumenta el tamaño muestral.

- Al igual que en el caso anterior, empezaremos por el p-valor. En la Fig. 6 podemos ver la representación gráfica de éstos. Desde el primer resultado con 10 muestras ya puede verse un p-valor muy pequeño, con lo que se rechazaría la hipótesis nula de igualdad de distribuciones.
- A continuación, representamos gráficamente el MAP de  $\rho$  en la Fig. 7. Como puede verse, la representación es prácticamente nula, como ocurría en el caso de los p-valores, lo que da como resultado el rechazo de la hipótesis nula.
- En cuanto a  $E_{\omega}[\rho]$ , podemos ver en la Fig. 8 la representación de éstas según el tamaño muestral. Al contrario que en la Fig. 4, en esta imagen tenemos que los valores esperados de  $\rho$  se van haciendo más pequeños a medida que aumenta el tamaño muestral, y, además, su variabilidad decrece de manera más rápida, por lo que es más exacta que en el caso anterior.
- Por último, vemos la representación gráfica de  $\text{Var}_{\omega}[\rho]$  en la Fig. 9. Como comentábamos en el caso de la Fig. 8, se ve que la representación es más exacta, cosa que también puede verse reflejada en la varianza de  $\rho$ , dado que llega un momento que es prácticamente nula.



#### IV-C. Comparación de $q(\rho|\omega)$ y P-valores cuando $p_1$ se aleja de $p_0$ , para un tamaño muestral fijo.

En este tercer y último experimento lo que hacemos es partir de dos distribuciones iniciales iguales y vamos modificando la segunda considerando un tamaño muestral fijo, en este caso,  $p_0 = (0.5, 0.2, 0.1, 0.1, 0.1)^T$  y el tamaño muestral de 50. Estas modificaciones vienen dadas mediante la expresión

$$p_1 = (1 - \lambda_i)p_0 + \lambda_i\lambda_u, \quad (5)$$

donde  $\lambda_i = \frac{i}{10}$  e  $i = 0, 1, 2, \dots, 10$ . Las representaciones gráficas que veremos a continuación son el resultado de ir comparando las distribuciones  $p_0$  y  $p_1$ .

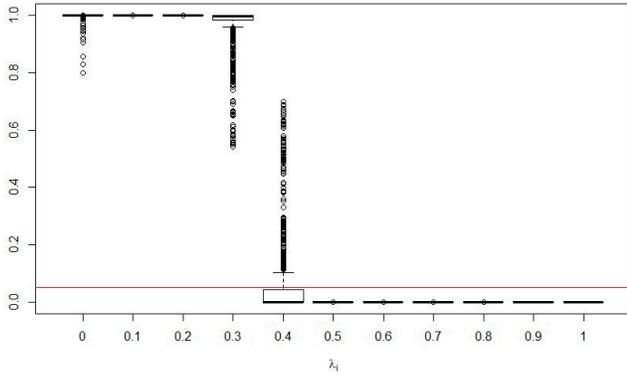


Figura 10: P-valor cuando una distribución se aleja de la otra según (5), para un tamaño muestral fijo. La línea roja horizontal muestra el p-valor 0.05.

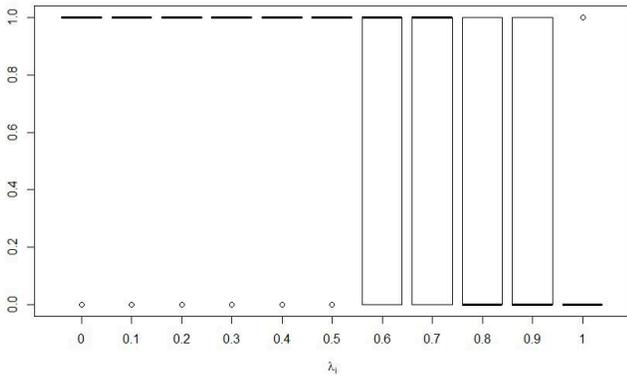


Figura 11: MAP de  $q(\rho|\omega)$  cuando una distribución se aleja de la otra según (5), para un tamaño muestral fijo.

De este experimento extraemos las siguientes conclusiones:

- En la Fig. 10 tenemos la representación de los p-valores para las distintas distribuciones. Puede verse que con las tres primeras distribuciones, las clasifica como iguales, es decir, se acepta la hipótesis nula; para 0.4, comete bastantes errores a la hora de clasificarlas; y a partir de 0.5 no hay evidencia suficiente para aceptar la hipótesis nula, lo que quiere decir que las dos distribuciones no serán iguales.

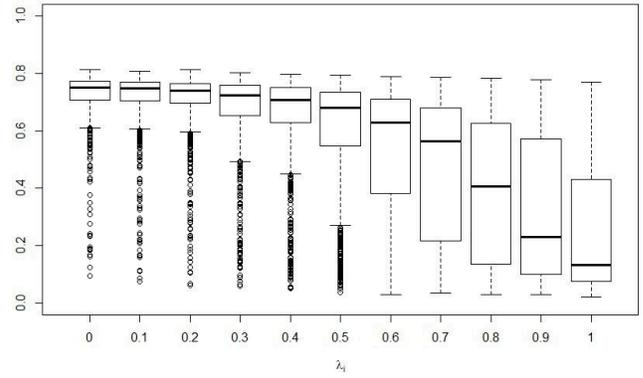


Figura 12:  $E_\omega[\rho]$  cuando una distribución se aleja de la otra según (5), para un tamaño muestral fijo.

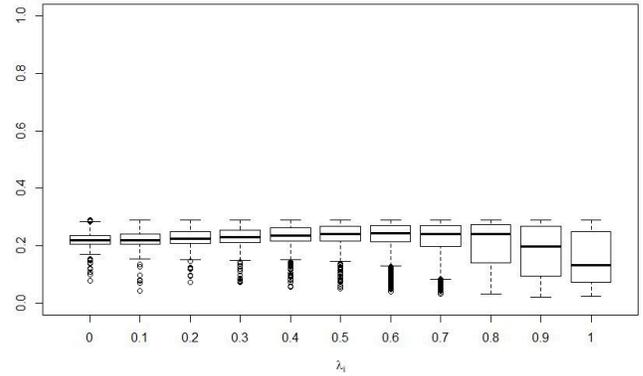


Figura 13:  $\text{Var}_\omega[\rho]$  cuando una distribución se aleja de la otra según (5), para un tamaño muestral fijo.

- En la figura Fig. 11 tenemos la representación gráfica del MAP. En este caso, podemos ver que se acepta la hipótesis nula hasta 0.7, pero para los valores entre 0.6 y 0.9 hay bastante error a la hora de tomar la decisión.
- La Fig. 12 está representada el valor esperado de  $\rho$  para cada una de las distintas probabilidades. Podemos ver que comenzamos con valores bastante altos debido a que las dos distribuciones son iguales en 0, y, a medida que vamos aumentando  $p_1$ , va tomando valores cada vez más pequeños. A su vez, puede verse que la variabilidad al comienzo es bastante más pequeña, y conforme se va avanzando en la gráfica, esta se va haciendo más grande.
- En cuanto a  $\text{Var}_\omega[\rho]$ , podemos ver en la Fig. 13 que hasta el valor 0.7 va creciendo un poco (lo que explica que la variabilidad de la gráfica anterior sea un poco mayor entre estos valores), pero decrece a partir de este hasta el final, tomando incluso un valor más bajo que en inicial.

## V. CONCLUSIONES Y TRABAJOS FUTUROS

En este artículo hemos explorado un test Bayesiano de dos muestras basado en el modelo HPP [2]. Este test devuelve una probabilidad *a posteriori* sobre la tasa de cambio de la distribución,  $p(\rho|x_0, x_1)$ . Hemos visto que se comporta de forma similar al test Chi-cuadrado cuando comparamos con el



valor MAP. Pero tiene la ventaja de que es capaz de cuantificar la incertidumbre asociada al tamaño de la muestra, al contrario que el test Chi-cuadrado. Como trabajos futuros, pretendemos extender el test para datos continuos y compararlo con otros test Bayesianos presentes en en la literatura.

#### REFERENCIAS

- [1] A. Martín, J. D. Luna, “Bioestadística para las ciencias de la salud (+)”, Capitel Editores, 2004.
- [2] A. Masegosa, T. D. Nielsen, H. Langseth, D. López-Ramos, A. Salmerón, A. L. Madsen, “Bayesian Models of Data Streams with Hierarchical Power Priors,” PMLR 70, Sydney, Australia, 2017.
- [3] G. M. Sullivan, R. Feinn, “Using effect size—or why the P value is not enough”, J Grad Med Educ, vol. 4, pp 279–282, 2012.
- [4] J. Nielsen, “Putting A/B testing in its place”, Useit.com Alertbox, 2005.
- [5] K. M. Borgwardt, Z. Ghahramani, “Bayesian two-sample tests”, *arXiv preprint arXiv:0906.4032*, Jun 2009.
- [6] M. D. Hoffman, D. M. Blei, C. Wang, J. Paisley, “Stochastic variational inference”, The Journal of Machine Learning Research, vol. 14, pp. 1303-1347, 2013.
- [7] W. L. Hu, P. C. Wu, L. Y. Pan, H. J. Yu, C. C. Pan, Y. C. Hung, “Effect of laser acupuncture on dry eye: A study protocol for a 2-center randomized controlled trial”, *Medicine*, vol. 97, Jun 2018.



# A Linear Programming Based Approach for Evaluating Interval-valued Influence Diagrams

Rafael Cabañas  
*Department of Mathematics*  
*University of Almería,*  
 Almería, Spain  
 rcabanas@ual.es

Andrés Cano, Manuel Gómez-Olmedo  
*Department of Computer Science and*  
*Artificial Intelligence, University of Granada,*  
 Granada, Spain  
 {acu,mgomez}@decsai.ugr.es

Alessandro Antonucci  
*Istituto Dalle Molle di Studi*  
*sull'Intelligenza Artificiale (IDSIA)*  
 Lugano, Switzerland  
 alessandro@idsia.ch

**Abstract**—This paper states the key ideas of a generalized version of variable elimination for evaluating interval-valued influence diagrams. This extension, which is based on linear programming, does not increase the computational complexity and avoids unnecessarily large outer approximations.

**Index Terms**—Influence diagrams, credal networks, imprecision, probability intervals, probabilistic graphical models

## I. INTRODUCTION

Influence diagrams (IDs) [5] are probabilistic graphical models used to solve decision-making problems under uncertainty. Sharp numerical values are required to quantify their parameters (i.e., potentials). This might be an issue with real models, whose parameters are typically obtained from expert judgements or partially reliable data. We consider an interval-valued quantification of the parameters to gain realism. Even though, inference in such models could be done by replacing the operations over sharp potentials with the analogous ones for interval-valued potentials, this might produce unnecessarily large outer approximations. To avoid that, we propose a sophistication of *variable elimination (VE)* based on linear programming. The content of this paper is discussed more in detail in a previous work [1].

## II. BACKGROUND

A discrete ID is defined over a set of chance variables  $\mathbf{X}$  and a set of decisions  $\mathbf{D}$ . The qualitative part is an acyclic directed graph  $\mathcal{G}$  with a node for each chance and decision variable. IDs contain a third type of node, namely utility nodes, representing the user preferences. These nodes are jointly denoted as  $\mathbf{U}$ . The quantitative part is made of a set of *probability potentials* (PPs) that represents the uncertainty, and a set of *utility potentials* (UPs) that represents the user preferences. A PP over two disjoint sets of variables  $X_I$  and  $X_J$ , denoted as  $\phi(X_I|X_J)$ , is a map  $\phi : \Omega_{X_I \cup J} \rightarrow [0, 1]$  such that  $\sum_{x_I \in \Omega_{X_I}} \phi(x_I|x_J) = 1$  for each  $x_J \in \Omega_{X_J}$ . Similarly, a UP over  $X_K$ , denoted as  $\psi(X_K)$ , is a map  $\psi : \Omega_{X_K} \rightarrow \mathbb{R}$ . For each chance node, a PP over the corresponding variable and its parents is defined, while, for each utility node, a UP over the parents should be assessed.

The set of all PPs specifies a multiplicative factorization of the joint probability of  $\mathbf{X}$  given  $\mathbf{D}$ . Thus, an ID

is a compact representation of a joint expected utility  $EU(\mathbf{X}, \mathbf{D}) := \prod_{X \in \mathbf{X}} \phi(X|\Pi_X) \sum_{U \in \mathbf{U}} \psi(\Pi_U)$ , where  $\Pi_Y$  is the set of parents of a given node  $Y$ . A *policy* for a decision variable  $D_i$  is a mapping  $\delta_{D_i} : \Omega_{\Pi_{D_i}} \rightarrow \Omega_{D_i}$  associating a state of  $D_i$  (i.e., a decision) to its past observations and decisions. Evaluating IDs (i.e., making inference) consists in the identification of the set of optimal strategies, which maximizes the expected value of the sum of the UPs. The *maximum expected utility (MEU)* is the expected value of the utilities when the decision maker takes the optimal policies.

VE is an algorithm for evaluating IDs [5] that eliminates all the variables one by one. In the version for IDs, chance variables are removed by sum while decision are instead eliminated by maximization. In order to remove a variable  $Y$ , all the potentials containing such variable in their domains are selected and combined<sup>1</sup>, giving as a result a PP and a UP denoted as  $\phi_Y$  and  $\psi_Y$ . In case of a chance variable, the new potentials replacing those containing  $Y$  are computed with Eq. (1). In case of a decision, Eq. (2) is used instead<sup>2</sup>.

$$(\phi'_Y, \psi'_Y) \leftarrow \left( \sum_Y \phi_Y, \frac{\sum_Y \phi_Y \cdot \psi_Y}{\sum_Y \phi_Y} \right) \quad (1)$$

$$(\phi'_Y, \psi'_Y) \leftarrow (\phi_Y^{R(Y=y)}, \max_Y \psi_Y) \quad (2)$$

## III. INTERVAL-VALUED IDS

### A. Definitions

Interval-valued IDs (IIDs) are a generalization of IDs containing imprecise parameters. For the utilities we base on the interval utilities proposed by Fertig and Brese [4], and we will call them *interval-valued utility potentials* (IUPs) and will be denoted by  $\underline{\psi}$ . For the probabilities, we use the notion of probability interval proposed by de Campos et al. [3], and we will use the term *interval-valued probability potential* (IPP) and will be denoted by  $\underline{\phi}$ . An example of both is given below.

$$\underline{\psi}(Y) = \begin{bmatrix} [-10, -5] \\ [-5, 5] \end{bmatrix} \begin{matrix} y_1 \\ y_2 \end{matrix} \quad \underline{\phi}(X) = \begin{bmatrix} [.475, .525] \\ [.285, .335] \\ [.190, .240] \end{bmatrix} \begin{matrix} x_1 \\ x_2 \\ x_3 \end{matrix} \quad (3)$$

<sup>1</sup>PPs are combined using *multiplication* whereas *addition* is used for UPs.

<sup>2</sup> $\phi^{R(\bullet)}$  denotes the restriction operation.

The difference w.r.t. the precise potentials is that, instead of single value, associated to each configuration there is an interval. Note that an interval-valued potential represents a bounded and infinite set of precise ones (its extension). We will assume that all the IUPs and IPPs have a non-empty extension and satisfy the reachability condition [3]. IIDs offer a direct sensitivity analysis interpretation. An IID can be regarded as a collection of so-called consistent IDs, all with the same graph and set of variables, with PPs and UPs taking their values from the extensions of the IPPs and IUPs of the IID.

### B. Evaluation by linear programming

IID evaluation is intended as the calculation of the interval spanned by the MEU values of the consistent IDs. The evaluation could be done by replacing the operations over sharp potentials with the analogous ones for interval-valued potentials [1], e.g., the multiplication of two IPP will be obtained by separately multiplying the lower and the upper bounds. This might produce unnecessarily large outer approximations. Note that the division Eq. (1) could lead to intervals with  $-\infty$  or  $+\infty$  in their bounds. Instead, we propose to use linear programming for the computation of the potentials resulting at each elimination step. Yet, the combination for interval-valued potentials will be still required for obtaining these programs.

First, let us consider the removal of a chance variable  $Y$  from a set of probabilities (i.e., left-hand side in Eq. (1)), then the equivalent operation with IPPs is defined as follows.

*Definition 1 (eliminating chance variables from IPPs):* Consider the elimination of the chance variable  $Y$  during VE. Let  $\bar{\phi}(X_I|X_J, Y)$  denote the IPP obtained by combining all the IPPs with  $Y$  on the right-hand side, and  $\bar{\phi}(Y, X_K|X_L)$  the only IPP with  $Y$  on the left. The elimination of  $Y$  from the combination of these two IPPs generates an IPP  $\bar{\phi}(X_K, X_I|X_L, X_J)$ . For each  $x_{I \cup K} \in \Omega_{X_{I \cup K}}$  and  $x_{L \cup J} \in \Omega_{X_{L \cup J}}$ , an outer approximation of the lower bound  $\bar{\phi}(x_{K \cup I}|x_{L \cup J})$  is the solution of the following task:

$$\begin{aligned} & \text{minimize} && \sum_{y \in \Omega_Y} \phi(x_I|x_J, y) \cdot \phi(y, x_K|x_L), \\ & \text{subject to} && \phi(x_I|x_J, y) \leq \phi(x_I|x_J, y) \leq \bar{\phi}(x_I|x_J, y), \\ & && \phi(y, x_K|x_L) \leq \phi(y, x_K|x_L) \leq \bar{\phi}(y, x_K|x_L), \forall y \in \Omega_Y. \end{aligned}$$

In case of computing the lower bound, we will replace  $\phi(x_I|x_J, y)$  with the lower bound  $\underline{\phi}(x_I|x_J, y)$ . This reduces the task to a linear program over the optimization variables  $\{\phi(y, x_K|x_L)\}_{y \in \Omega_Y}$ . Analogously, an outer approximation of the upper bound  $\bar{\phi}(x_{K \cup I}|x_{L \cup J})$  can be calculated by maximizing the previous objective function instead and replacing  $\phi(x_I|x_J, y)$  with  $\bar{\phi}(x_I|x_J, y)$ . Now consider the right-hand side in Eq. (1), then the equivalent operation with IUPs is defined as follows.

*Definition 2 (eliminating chance variables from IUPs):* Let  $\bar{\phi}(X_I|X_J, Y)$  be the IPP obtained by combining all the IPPs with  $Y$  on the right-hand side,  $\bar{\phi}(Y, X_K|X_L)$  be the only IPP

with  $Y$  on the left-hand side and  $\bar{\psi}(Y, X_M)$  the combination of all the IUPs with  $Y$  in the argument. The elimination of a chance variable  $Y$  from the combination of these potentials produces a new IPP  $\bar{\psi}(X_I, X_J, X_K, X_L, X_M)$ . For each  $x_{I \cup J \cup K \cup L \cup M} \in \Omega_{X_{I \cup J \cup K \cup L \cup M}}$ , an outer approximation of the lower bound  $\underline{\psi}(x_{I \cup J \cup K \cup L \cup M})$  is the solution of the task

$$\begin{aligned} & \text{minimize} && \frac{\sum_{y \in \Omega_Y} \phi(x_I|x_J, y) \cdot \phi(y, x_K|x_L) \cdot \psi(y, x_M)}{\sum_{y \in \Omega_Y} \phi(x_I|x_J, y) \cdot \phi(y, x_K|x_L)}, \\ & \text{subject to} && \underline{\phi}(x_I|x_J, y) \leq \phi(x_I|x_J, y) \leq \bar{\phi}(x_I|x_J, y), \\ & && \underline{\phi}(y, x_K|x_L) \leq \phi(y, x_K|x_L) \leq \bar{\phi}(y, x_K|x_L), \\ & && \underline{\psi}(y, x_M) \leq \psi(y, x_M) \leq \bar{\psi}(y, x_M), \forall y \in \Omega_Y. \end{aligned}$$

The task has a linearly constrained cubic-fractional objective function. When calculating the lower bound, the minimization with respect to the optimization variables associated to an IUP can be trivially achieved by setting  $\psi(y, x_M) = \underline{\psi}(y, x_M)$ . We can also regard the product  $\phi(y, x_K|x_L) \cdot \bar{\phi}(x_I|x_J, y)$  as a single optimization variable. In this way the task becomes a linear-fractional program which can be reduced to a linear program using the classical Charnes-Cooper transformation [2]. Analogously, a similar procedure can be done for the upper bound  $\bar{\psi}(x_{I \cup J \cup K \cup L \cup M})$ .

The elimination of a decision (i.e., Eq. (2)) is done using the analogous operations for interval-valued potentials without introducing any imprecision. To obtain the optimal policy, we adopt a conservative approach, called *interval dominance* in the imprecise-probability jargon, which rejects all the decisions leading to certainly sub-optimal strategies.

## IV. CONCLUSIONS

In this paper we have proposed an extension of the classical VE for evaluating IDs whose parameters are interval-valued potentials. This extension is achieved by local optimization tasks, reduced to linear programs. An empirical analysis of this method can be found in a previous work [1]. As a future work we intend to extend this formalism to more general imprecise frameworks, e.g., credal sets represented by extreme points.

## ACKNOWLEDGMENT

Authors have been jointly supported by the Spanish Ministry of Science, Innovation and Universities and by FEDER under the projects TIN2015-74368-JIN, TIN2016-77902-C3-2-P and TIN2016-77902-C3-3-P.

## REFERENCES

- [1] R. Cabañas, A. Antonucci, A. Cano, and M. Gómez-Olmedo. Evaluating interval-valued influence diagrams. *International Journal of Approximate Reasoning*, 80:393–411, 2017.
- [2] A. Charnes and W. W. Cooper. Programming with linear fractional functionals. *Naval Research Logistics Quarterly*, 9(3-4):181–186, 1962.
- [3] L. M. de Campos, J. F. Huete, and S. Moral. Probability intervals: a tool for uncertain reasoning. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 2(02):167–196, 1994.
- [4] K. W. Fertig and J. S. Breese. Probability intervals over influence diagrams. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(3):280–286, 1993.
- [5] F. V. Jensen and T. D. Nielsen. *Bayesian networks and Decision Graphs*. Springer Verlag, 2007.



# Algoritmos basados en árboles de decisión para *partial* label ranking

Juan C. Alfaro

Escuela Superior de Ingeniería Informática  
Universidad de Castilla-La Mancha  
Albacete, 02071, España.  
Email: JuanCarlos.Alfaro1@alu.uclm.es

Juan A. Aledo

Dpto. de Matemáticas  
Univ. de Castilla-La Mancha  
Albacete, 02071, España.  
Email: JuanAngel.Aledo@uclm.es

José A. Gámez

Dpto. de Sistemas Informáticos  
Univ. de Castilla-La Mancha  
Albacete, 02071, España.  
Email: Jose.Gamez@uclm.es

**Resumen—**Por *Label Ranking (LR)* se denomina a un problema de clasificación supervisada no estándar, en el sentido de que el objetivo no es predecir una etiqueta de la variable clase, si no un ranking completo de las posibles etiquetas. Además, las instancias del conjunto de entrenamiento también están etiquetadas con rankings, no con una única etiqueta. En este trabajo proponemos extender este problema de clasificación al *Partial Label Ranking (PLR)* en el que tanto los rankings asociados a las instancias de entrenamiento como a la predicción, puede contener etiquetas empatadas, es decir, para las que no hay preferencia entre ellas. Este escenario, que se da frecuentemente en el mundo real, evita tener que introducir desempates artificiales. Siguiendo uno de los trabajos seminales de LR, proponemos algoritmos de aprendizaje automático basados en los vecinos más cercanos y en árboles de clasificación para abordar el PLR. La experimentación realizada muestra la competencia de los algoritmos propuestos en la resolución del PLR.

## I. INTRODUCCIÓN

El problema de la clasificación supervisada (o simplemente clasificación) es probablemente el más estudiado y aplicado en el ámbito del aprendizaje automático y ciencia de datos [1]. En un problema de clasificación, se dispone de un conjunto de variables predictoras  $\{X_1, \dots, X_m\}$  que pueden ser numéricas o discretas, y de una variable distinguida, la *clase*,  $C$ , que toma valores en un conjunto finito de etiquetas o categorías  $dom(C) = \{c_1, \dots, c_n\}$ . Definido sobre estas variables se dispone de un conjunto de datos  $\{(x_1^j, x_2^j, \dots, x_m^j, c_k^j)\}_{j=1}^N$  donde  $N$  es el número de instancias y  $j$  indica el número de instancia. El objetivo de la clasificación automática es el aprendizaje a partir de los datos de un clasificador (o función de clasificación)

$$C : dom(X_1) \times dom(X_2) \times \dots \times dom(X_m) \longrightarrow C$$

que generalice bien a partir de los datos de entrada y pueda, por tanto, aplicarse exitosamente para clasificar datos nuevos.

En los últimos años han aparecido una serie de problemas aplicados, que si bien corresponden a tareas de clasificación supervisada, no encajan en la definición anterior, dando lugar a los conocidos problemas de clasificación *no estándar* [2]. Este grupo de tareas de clasificación se caracteriza por una débil supervisión en las instancias del conjunto de datos, la existencia de una estructura interna en el *objetivo* a predecir, o ambas cuestiones simultáneamente.

En este trabajo tomamos como base uno de estos problemas, de aparición bastante reciente, como es el de los clasificadores de tipo *Label Ranking (LR)* [3], cuyo objetivo es predecir un ranking total (todas las etiquetas se ordenan y el orden es estricto) entre las etiquetas de la variable clase a partir de los valores de las variables observadas. A diferencia de problemas relacionados como puede ser la clasificación ordinal, en la tarea de LR las instancias vienen etiquetadas con un ranking de las etiquetas de la variable clase, no con una única etiqueta. Esta información es explotada para construir el clasificador LR. A modo de ejemplo, supongamos que queremos recomendar a un futuro estudiante de nuestra universidad una lista ordenada de los estudios que pensamos le pueden ir bien en función de su historial de notas en Bachillerato, sus hobbies, etc. Por ejemplo, podríamos recomendar matemáticas  $\prec$  informática  $\prec$  biología  $\prec$  medicina a un estudiante con excelentes habilidades matemáticas y cuyo hobby sea la programación. Basándose en la activa investigación en el campo de la agregación de rankings [4] y en los modelos clásicos de aprendizaje automático, en [3] se proponen dos algoritmos para aprender clasificadores LR, uno basado en los vecinos más cercanos (*IBLR*) y otro en árboles de clasificación/regresión (*LRT*) (ver Sección II).

En el ámbito de la agregación de rankings podemos encontrar problemas cuyo objetivo es descubrir ranking parciales (alias débiles) [5], [6], i.e., con empates. Estos rankings son más generales puesto que no fuerzan a tomar decisiones de desempate de forma poco natural y rigurosa. Continuando con nuestro ejemplo anterior, supongamos que dadas las variables predictoras para un estudiante determinado, basamos nuestra recomendación o predicción en la selección que en su día hicieron los dos estudiantes más parecidos a nuestro sujeto:

*est.1* : matemáticas  $\prec$  informática  $\prec$  biología  $\prec$  medicina

*est.2* : matemáticas  $\prec$  biología  $\prec$  informática  $\prec$  medicina

Es indudable que matemáticas debería ser la primera opción del ranking y medicina la última, pero no tenemos evidencia para ordenar entre informática y biología, por lo que lo más *natural* sería dejarlas empatadas, produciendo así un ranking parcial:

predicción: matemáticas  $\prec$  informática  $\sim$  biología  $\prec$  medicina

Nuestro objetivo en este trabajo es extender el problema de la clasificación LR a este marco más general que denominamos *Partial Label Ranking (PLR)*, y en el que si bien todas las etiquetas de la variable clase son ordenadas, el ranking no es estricto, si no que puede haber etiquetas empatadas. Tomando como base [3] diseñamos dos algoritmos de clasificación PLR basados en el método de los vecinos más cercanos (*IBPLR*) y en árboles de clasificación/regresión (*PLRT*) (ver Sección III).

El resto del artículo se organiza como sigue. En la Sección II repasamos los conceptos básicos para trabajar con rankings e introducimos los clasificadores principales para LR. En la Sección III describimos nuestra propuesta de algoritmos de clasificación para el PLR. En la Sección IV describimos el estudio empírico llevado a cabo para evaluar los métodos diseñados en este artículo. Finalmente, en la Sección V proporcionamos algunas conclusiones.

## II. PRELIMINARES: CLASIFICADORES LABEL RANKING

Comenzamos por introducir algunos conceptos relativos a la agregación de rankings, para después revisar brevemente los algoritmos de clasificación LR propuestos en [3]. Nos ceñimos al caso de rankings completos, que es el contemplado en este artículo, aunque en [3] se proporcionan herramientas para gestionar el caso de que las instancias puedan contener rankings incompletos. Tampoco se describen algoritmos más avanzados como pueden ser los basados en ensembles [7], [8].

### A. Agregación de rankings

Dado un conjunto de items  $\mathcal{I} = \{1, 2, \dots, n\}$ , un ranking  $\pi$  expresa un orden de preferencia sobre (algunos de) esos items. El conjunto de rankings completos y estrictos (permutaciones) de  $\mathcal{I}$  es el grupo simétrico  $\mathbb{S}_n$ . Denotamos con  $\tilde{\mathbb{S}}_n$  el conjunto de rankings (completos o incompletos, totales o parciales) definidos sobre  $\mathcal{I}$ .

Dado un conjunto o muestra de  $N$  rankings  $\{\pi_1, \pi_2, \dots, \pi_N\}$ ,  $\pi_i \in \tilde{\mathbb{S}}_n$ , el *problema de agregación de rankings (RAP)* consiste en obtener la permutación  $\pi_0 \in \mathbb{S}_n$  que mejor representa a los rankings contenidos en la muestra, es decir, el que minimiza la suma de las distancias a los rankings contenidos en la muestra.  $\pi_0$  se conoce como el *ranking de consenso*.

Dependiendo del tipo de rankings a considerar en la muestra, en la salida (consenso) y de la distancia utilizada, aparecen distintas variantes del RAP, siendo probablemente el más estudiado el caso de la agregación de ranking completos y totales (permutaciones), conocido como *Kemeny Ranking Problem (KRP)*. Los problemas de agregación de rankings son NP-completos y por ello han proliferado los métodos heurísticos para abordarlos. En el caso de KRP, el más usado tanto por su sencillez como por su rapidez, es el algoritmo de conteo de Borda [9]. Además, en el caso de permutaciones, un conjunto de rankings puede modelarse probabilísticamente mediante la distribución de Mallows, la cual se especifica con dos parámetros: la moda o permutación de consenso  $\pi_0$ ; y  $\theta$ , un número real que mide la dispersión en torno a la moda, de forma que un mayor valor de  $\theta$  indica una mayor

concentración de los rankings alrededor de la moda. Cuando estos valores deben ser estimados un número importante de veces, el algoritmo de Borda es usado para estimar  $\pi_0$  y  $\theta$  se estima a partir de  $\pi_0$  y de los datos mediante métodos iterativos.

Cuando la entrada y la salida al problema son rankings completos y parciales (o *bucket orders*), nos encontramos ante el problema conocido como *Optimal Bucket Order Problem (OBOP)* [5]. El objetivo del OBOP es minimizar la distancia entre la matriz de ordenación por pares obtenida a partir de un conjunto de preferencias de distintos individuos y la matriz de buckets asociada a un bucket order. Este es un problema menos estudiado que KRP y, por ejemplo, no conocemos una distribución de probabilidad para modelar un conjunto de bucket orders. Si hay, sin embargo, distintos métodos heurísticos para resolver la agregación y obtener el bucket order de consenso como son *Bucket Pivot Algorithm (BPA)* [5] y versiones mejoradas del mismo, p.e. BPA multipivote [6].

### B. Clasificador IBLR: Instance-Based Label Ranking

Se trata de una adaptación del método de los vecinos más cercanos ( $k$ NN) al problema del label ranking. Así, para clasificar un nuevo caso  $(\mathbf{x}, ?)$  se calcula la distancia (usando las variables predictoras) a las  $N$  instancias de la base de datos y se seleccionan las  $k$  más cercanas. La adaptación al caso del LR reside en la decisión de la respuesta a generar, puesto que ahora un voto por la mayoría no es oportuno. Así, si los rankings asociados a las  $k$  instancias recuperadas son  $\Pi_k = \{\pi_1, \dots, \pi_k\}$ , la respuesta a devolver es el ranking de consenso  $\pi_0$  obtenido al resolver el RAP asociado a  $\Pi_k$ . En [3] se usa el método de conteo de Borda [9] para obtener  $\pi_0$ .

Algunas mejoras propuestas en [3] son la estimación del valor de  $k$  usando validación cruzada o la posibilidad de pesar los rankings por la inversa de la distancia, usando entonces el método de conteo de Borda con pesos.

### C. Clasificador LRT: Label Ranking Tree

Se trata de un algoritmo estándar de construcción de un árbol de clasificación/regresión a partir de datos, usando para ello un particionamiento recursivo del conjunto de datos. Tres son las principales cuestiones que hay que resolver para adaptar el algoritmo de aprendizaje al caso LR:

- Criterio de parada. Evidentemente el proceso de ramificación se detiene si los rankings de todas las instancias que han llegado al nodo actual son iguales. Además, en [3] el proceso también se detiene, dando lugar a un nodo hoja, cuando el número de instancias que han llegado al nodo actual es menor o igual que  $2n$ . Esta condición se propone como un criterio de pre-poda.
- Respuesta asignada a un nodo hoja. Se asigna a la hoja el ranking de consenso de todas las instancias que llegan a ella.
- Variable a seleccionar (y umbral) para los nodos de decisión. Al igual que en los árboles de clasificación con la entropía o en los de regresión con la varianza, se toma



la decisión que genera la partición de mínima dispersión para la variable objetivo. En [3] se usa la distribución de Mallows para medir esta dispersión. Si  $\Pi$  es el conjunto de rankings correspondientes a las instancias que llegan al nodo actual, se estima la distribución de Mallows  $\mathcal{M}(\pi_0, \theta)$  a partir de ellos. Dada una variable predictora  $X$  tomando valores en  $dom(X) = \{x_1, \dots, x_r\}$ , se divide el conjunto de instancias en función de estos valores. A partir de los conjuntos de rankings  $\{\Pi_1, \dots, \Pi_r\}$  correspondientes a la partición realizada, se estiman entonces  $r$  distribuciones de Mallows  $\mathcal{M}^i(\pi_0^i, \theta^i)$ ,  $i = 1, \dots, r$ , cada una correspondiente a un conjunto de la partición (una rama). Si  $\theta$  es menor que

$$\sum_{i=1}^r \frac{|\Pi_i| \cdot \theta_i}{|\Pi|} \quad (1)$$

quiere decir que nuestra variable ha generado una buena partición, puesto que los rankings están más concentrados en torno a su consenso ( $\theta_i$ ), por lo que éste es una mejor predicción. Este criterio (similar al uso de la entropía) se comprueba para todas las variables, eligiéndose la que maximiza (1). En el caso de variables numéricas se sigue el procedimiento estándar de probar todos los umbrales y elegir el que maximiza (1) para la partición  $X \leq t$  y  $X > t$ .

### III. APRENDIZAJE DE CLASIFICADORES PARA LR PARCIAL

En esta sección describimos como adaptamos el clasificador IBLR [3] para tratar con PLR (IBPLR) y nuestras propuestas para este problema basándonos en LRT [3] (PLRT).

#### A. Clasificador IBPLR: Instance-Based Partial Label Ranking

Al igual que el algoritmo IBLR, IBPLR es una adaptación del método de los vecinos más cercanos ( $k$ NN) para trabajar con PLR. Así, si los bucket orders asociados a las  $k$  instancias recuperadas son  $\Pi_k = \{\pi_1, \dots, \pi_k\}$ , la respuesta a devolver es el bucket order de consenso  $\pi_0$  obtenido al resolver el OBOP asociado a  $\Pi_k$ . Para resolver dicho problema, se utiliza el algoritmo BPA multipivote, que obtiene mejores resultados que BPA [6].

#### B. Clasificador PLRT: Partial Label Ranking Trees

Como en LRT, PLRT debe solucionar tres cuestiones principales para adaptar el algoritmo de aprendizaje al caso PLR:

- Criterio de parada. Como es usual, el algoritmo de aprendizaje debe parar la llamada recursiva y crear un nodo hoja cuando los bucket orders de las instancias que llegan al nodo actual son iguales. Además, al igual que en [3], se impone una condición de pre-poda cuando el número de instancias que llegan al nodo actual es menor que  $q$ , siendo  $q$  un parámetro a especificar al algoritmo de aprendizaje.
- Respuesta asignada a un nodo hoja. Se asigna al nodo hoja el bucket order de consenso obtenido al solucionar el OBOP con el conjunto de bucket orders de las instancias que llegan al nodo actual, usando BPA multipivote [6].

- Variable a seleccionar (y umbral) para los nodos de decisión. Como se comentó anteriormente, el problema que se plantea es que, hasta donde conocemos, no existe una distribución de probabilidad para bucket orders. Por tanto, no podemos usar la misma metodología que en [3] y proponemos métodos alternativos. Así, si tomamos el conjunto de bucket orders asociados a las instancias que llegan al nodo actual  $\Pi$  y una variable predictora  $X$ , la incertidumbre asociada a la partición  $\{\Pi_1, \dots, \Pi_r\}$  generada por el atributo  $X$  viene dada por

$$\sum_{i=1}^r \frac{|\Pi_i| \cdot \phi_i}{|\Pi|} \quad (2)$$

donde  $\phi_i$  es un parámetro a ser estimado para la partición  $\Pi_i$ . Por ejemplo, en el caso de LR,  $\phi_i$  se toma como el parámetro de dispersión  $\theta_i$ . En PLR, proponemos las siguientes alternativas:

- Entropía. Para todos los pares de etiquetas (distintas) ( $c_j, c_k$ ) con  $c_j, c_k \in dom(C)$ , se calcula la probabilidad de que la etiqueta  $c_j$  preceda, empate y suceda a  $c_k$  de acuerdo al conjunto de bucket orders en  $\Pi_i$ . Con esto, se obtiene una distribución de probabilidad para cada combinación de pares. El parámetro  $\phi_i$  se calcula como la entropía media de las distribuciones de probabilidad obtenidas.

**Ejemplo III.1.** Consideramos el conjunto de bucket orders  $\Pi_i = \{2 \sim 1 \prec 3, 1 \prec 3 \prec 2, 1 \prec 2 \sim 3, 2 \prec 1 \prec 3, 3 \prec 1 \sim 2\}$ . Así, el parámetro  $\phi_i$  se estima como sigue usando la alternativa basada en entropía

$$\begin{aligned} \phi_i &= media\{H(\overbrace{((0.4, 0.4, 0.2))}^{\text{Par (1,2)}}, H(\overbrace{((0.8, 0, 0.2))}^{\text{Par (1,3)}}, \\ &\quad H(\overbrace{((0.4, 0.2, 0.4))}^{\text{Par (2,3)}})\} \\ &= media\{1.522, 0.722, 1.522\} = 1.255 \end{aligned}$$

- Desacuerdo. Utilizando el bucket order de consenso obtenido a partir de  $\Pi_i$ , se calcula la frecuencia (relativa) de desacuerdos entre este y los incluidos en  $\Pi_i$ . Un desacuerdo existe si el orden de un par de items en los bucket orders a considerar es distinto, incluyendo el caso en que un par está empatado en un bucket order, pero no en el otro.

**Ejemplo III.2.** Considerando el conjunto de bucket orders del ejemplo previo y el bucket order de consenso  $\mathcal{B}_0 = 1 \sim 2 \sim 3$  (obtenido mediante BPA multipivote [6]), la estimación del parámetro  $\phi_i$ , usando el método basado en desacuerdo es

$$\phi_i = \frac{\overbrace{3}^{\text{Desacuerdos par (1,2)}} + \overbrace{5}^{\text{Desacuerdos par (1,3)}} + \overbrace{4}^{\text{Desacuerdos par (1,2)}}}{\underbrace{15}_{\text{Normalización}}} = \frac{12}{15} = 0.8$$

Cabe destacar que, para optimizar el proceso de aprendizaje, se puede construir una matriz de tamaño  $n \times n$  donde cada celda contiene un par ordenado con el número de veces que un item precede y empata con otro. De este modo, lo que se consigue es que para obtener la incertidumbre usando cada una de las alternativas propuestas, no es necesario recorrer todos los bucket orders de nuevo, sino que solo es necesario recuperar la información necesaria de dicha matriz (ver [10] para detalles).

#### IV. EVALUACIÓN EXPERIMENTAL

En esta sección llevamos a cabo un estudio experimental de los métodos propuestos. A continuación describimos los conjuntos de datos utilizados, algoritmos involucrados, metodología y resultados.

##### A. Conjuntos de datos

Se han generado bases de datos semi-sintéticas siguiendo el esquema propuesto en [3]. Específicamente, tomamos 11 conjuntos de datos multiclase de [11] y los transformamos a bucket orders, considerándolos, por tanto, semisintéticos. La idea básica es resolver un problema de clasificación estándar, usando, en nuestro caso, Random Forest. Para cada instancia se rankean sus etiquetas de acuerdo a la distribución de probabilidad de la clase dada la instancia. Posteriormente se inicia un proceso de fusión de algunas etiquetas en buckets, siempre que la distancia entre ambas distribuciones de probabilidad (antes y después de colapsar) no superen un umbral establecido (0.05 en nuestros experimentos, ver [10] para detalles). En la Tabla I se muestran las principales características de los conjuntos de datos. Las columnas #etiquetas y #orders se corresponden con el número de etiquetas de la variable clase y el número de bucket orders distintos generados, respectivamente.

TABLA I  
DESCRIPCIÓN DE LOS CONJUNTOS DE DATOS.

Cjto. de datos	#instancias	#atributos	#etiquetas	#orders
authorship	841	70	5	5
breast	106	9	6	22
ecoli	336	7	8	39
glass	214	9	6	23
iris	150	4	3	6
pendigits	10992	16	10	60
segment	2310	18	7	20
shuttle	43500	9	9	18
vehicle	846	18	4	13
vowel	528	10	11	23
wine	178	13	3	5

##### B. Algoritmos

Consideramos los siguientes algoritmos en el estudio:

- El algoritmo IBPLR pre-calculando (T-IBPLR) y sin pre-calculador (F-IBPLR) las distancias entre las instancias de los conjuntos de datos. Para identificar los vecinos más

cercanos, utilizamos la distancia Euclídea. El número de vecinos más cercanos,  $k$ , se ajusta mediante una cinco validación cruzada (5-cv) interna sobre cada conjunto de entrenamiento correspondiente a cada uno de los folds de la validación cruzada externa, sin usar en ningún caso los registros de la partición test correspondiente para ajustar el valor de  $k$ . Dicho valor se ajusta como sigue. Primero, se va multiplicando (por 2, empezando por 5) el número de vecinos más cercanos mientras se mejore la precisión. Segundo, con los dos últimos valores probados, se hace un búsqueda binaria en ese rango. Se elige el número de vecinos más cercanos que conduzca a una mayor precisión.

- Las propuestas de PLRT, usando el método basado en entropía sin y con pre-poda (E-PLRT y PrE-PLRT, respectivamente), e idénticamente para la propuesta basada en desacuerdo (A-PLRT y PrA-PLRT). En todos los casos la pre-poda se aplica con  $q = 5$ .

##### C. Metodología

Adoptamos las siguientes decisiones de diseño:

- Todos los algoritmos han sido evaluados usando cinco repeticiones de una diez validación cruzada ( $5 \times 10$ -cv) como en [3].
- Para evaluar la precisión de los algoritmos, utilizamos el coeficiente de correlación para rankings  $\tau_X$  [12]. Dado los bucket orders  $\mathcal{B}_a$  y  $\mathcal{B}_b$ , el coeficiente de correlación de rankings  $\tau_X$  viene dado por

$$\tau_X(\mathcal{B}_a, \mathcal{B}_b) = \frac{\sum_{i=1}^n \sum_{j=1}^n \beta_{ij}^r \beta_{ij}^p}{n(n-1)} \quad (3)$$

donde

$$\beta_{ij}^k = \begin{cases} 1, & \text{si } c_i \text{ precede o empata con } c_j \text{ en } \mathcal{B}_k \\ -1, & \text{si } c_i \text{ sucede a } c_j \text{ en } \mathcal{B}_k \\ 0, & \text{si } i = j \end{cases}$$

El coeficiente de correlación de rankings  $\tau_X$  toma valores en el intervalo  $[-1, 1]$ , de tal manera que valores próximos a 1 indican una mejor correlación entre los bucket orders  $\mathcal{B}_a$  y  $\mathcal{B}_b$  mientras que valores próximos a 0 indican una peor correlación.

- Los algoritmos han sido implementados en Python 3.6.5 y ejecutados en ordenadores con sistema operativo Ubuntu 16.04.2 con CPU Intel Core i7-6700 a 3.40GHz y 16GB de memoria RAM.

##### D. Resultados

A continuación se muestran los resultados en términos de precisión y tiempo junto con su correspondiente análisis.

1) *Precisión*: Los resultados en términos de precisión se muestran en la Tabla II. Cada celda contiene la media del coeficiente  $\tau_X$  [12] entre los rankings reales y predichos sobre los conjuntos de datos de test para la  $5 \times 10$ -cv. Para hacer más fácil la interpretación de los resultados, el (los) algoritmo(s)



TABLA II  
PRECISIÓN MEDIA PARA CADA ALGORITMO.

Cjto. de datos	F-IBPLR	T-IBPLR	A-PLRT	PrA-PLRT	E-PLRT	PrE-PLRT
authorship	<b>0.9945</b>	<b>0.9945</b>	0.9461	0.9462	0.9468	0.9470
breast	0.7820	0.7820	0.7896	0.7832	0.8039	<b>0.8058</b>
ecoli	<b>0.8994</b>	<b>0.8994</b>	0.8764	0.8832	0.8829	0.8805
glass	0.7787	0.7787	0.7907	0.7907	<b>0.8187</b>	0.8165
iris	0.9582	0.9582	0.9560	0.9502	<b>0.9613</b>	0.9560
pendigits	<b>0.9953</b>	<b>0.9953</b>	0.9802	0.9802	0.9838	0.9838
segment	0.9603	0.9603	0.9776	0.9777	<b>0.9794</b>	0.9782
shuttle	0.9991	-	0.9996	0.9996	0.9997	<b>0.9998</b>
vehicle	0.7426	0.7426	0.7223	0.7271	0.7479	<b>0.7483</b>
vowel	<b>0.9672</b>	<b>0.9672</b>	0.8903	0.8898	0.9133	0.9119
wine	<b>0.9393</b>	<b>0.9393</b>	0.8921	0.8901	0.8971	0.9014

TABLA III  
RESULTADOS DEL POST-HOC TEST PARA LA PRECISIÓN MEDIA.

Método	ranking	p-valor	victorias	empates	perdidos
E-PLRT	2.55	-	-	-	-
PrE-PLRT	2.68	<b>1.0000e+00</b>	5	0	6
F-IBPLR	3.18	<b>1.0000e+00</b>	6	0	5
T-IBPLR	3.27	<b>1.0000e+00</b>	6	0	5
A-PLRT	4.59	4.1376e-02	11	0	0
PrA-PLRT	4.73	3.1185e-02	10	0	1

con la mejor precisión están en negrita. Cabe destacar que el valor perdido en la celda correspondiente al algoritmo T-IBPLR para el conjunto de datos *shuttle* se debe a un error en memoria cuando se intenta almacenar las distancias entre todas las instancias.

El análisis estadístico se ha llevado a cabo utilizando el procedimiento estándar en aprendizaje automático descrito en [13], [14], utilizando el software disponible en [15]. Este procedimiento consta de dos pasos:

- Primero, hemos llevado a cabo un test de Friedman [16] con un nivel de significación de  $\alpha = 0.05$ . Puesto que el p-valor obtenido es  $1.6112e^{-2}$ , la hipótesis nula (de que todos los algoritmos son equivalentes en términos de precisión) es rechazada.
- Tras ello, hemos realizado un post-hoc test aplicando el procedimiento de Holm [17] con un nivel de significación de  $\alpha = 0.05$ . Básicamente, este test toma, como control, el algoritmo rankeado primero por el test de Friedman (E-PLRT) y se utiliza para descubrir métodos destacados.

Los resultados para el post-hoc test se muestran en la Tabla III. En esta se muestra el ranking obtenido por el test de Friedman y el p-valor ajustado por el procedimiento de Holm. Las columnas victorias, empates y perdidos se corresponde con el número de veces que el método de control gana, empatan o pierde con el algoritmo correspondiente. Los p-valores en negrita se corresponden con hipótesis nulas no rechazadas.

De acuerdo a estos resultados, podemos concluir que:

- El algoritmo E-PLRT está rankeado en la primera posición por el test de Friedman y, por tanto, es utilizado como control. De hecho, la versión con pre-poda (PrE-

TABLA IV  
TIEMPO REQUERIDO POR CADA ALGORITMO (EN SEGUNDOS).

Cjto. de datos	F-IBPLR	T-IBPLR	A-PLRT	PrA-PLRT	E-PLRT	PrE-PLRT
authorship	1379.9	<b>91.3</b>	1760.0	1721.2	1411.2	1390.7
breast	38.2	<b>17.9</b>	270.1	252.3	314.5	291.2
ecoli	321.4	<b>103.3</b>	754.1	714.5	635.5	587.7
glass	139.4	<b>42.8</b>	635.0	600.3	556.5	520.0
iris	53.4	<b>10.6</b>	17.3	16.5	17.3	16.5
pendigits	205683.2	<b>6060.3</b>	33125.0	32205.9	28231.4	27622.2
segment	9431.9	<b>558.3</b>	10033.2	9862.7	9957.3	9791.8
shuttle	3113337.0	-	28378.8	28167.7	13507.7	<b>13439.6</b>
vehicle	1282.7	<b>83.9</b>	1896.3	1828.4	1538.5	1459.5
vowel	715.9	<b>243.6</b>	9829.5	9603.5	6737.8	6636.1
wine	78.0	<b>13.5</b>	159.7	158.4	132.1	128.8

TABLA V  
RESULTADOS DEL POST-HOC TEST PARA EL TIEMPO.

Método	ranking	p-valor	victorias	empates	perdidos
T-IBPLR	1.45	-	-	-	-
PrE-PLRT	2.91	<b>1.0541e-01</b>	10	0	1
F-IBPLR	3.00	<b>1.0541e-01</b>	10	0	1
E-PLRT	4.09	2.8507e-03	10	0	1
PrA-PLRT	4.18	2.5158e-03	10	0	1
A-PLRT	5.36	4.7844e-06	10	0	1

PLRT) se encuentra en la segunda posición a pesar de ganar en seis ocasiones (de un total de once) a la propuesta sin ella.

- Las propuestas A-PLRT y PrA-PLRT están rankeadas en las últimas posiciones por el test de Friedman. Por tanto, tener en cuenta la sub-solución al problema en cada uno de los nodos del árbol no parece conducir (al menos en estas bases de datos) a mejores árboles en términos de precisión.
- Los resultados del post-hoc test revelan que los métodos T-IBPLR, F-IBPLR y PrE-PLRT no muestran diferencia estadística significativa con respecto al algoritmo E-PLRT.

2) *Tiempo*: En este artículo hemos trabajado con dos paradigmas del aprendizaje automático cuyo tiempo requerido para inducción e inferencia es claramente distinto. Para hacer una comparación adecuada, el tiempo de la CPU para el proceso completo (aprendizaje con el conjunto de entrenamiento y validación con el de test) sobre la  $5 \times 10$ -cv ha sido utilizado. Los resultados se muestran en la Tabla IV.

Como antes, hemos llevado a cabo el análisis estadístico descrito en [13], [14]:

- En el test de Friedman [16] con un nivel de significación de  $\alpha = 0.05$  se obtiene un p-valor de  $2.8972e^{-5}$ . Por tanto, la hipótesis nula (de que todos los algoritmos son equivalentes en términos de tiempo) es rechazada.
- Por otro lado, el post-hoc test usando el procedimiento de Holm [17] con un nivel de significación de  $\alpha = 0.05$  se muestra en la Tabla V.

De acuerdo a los resultados obtenidos, podemos concluir que:

- El test de Friedman rankea en primera posición el algoritmo T-IBPLR y, por tanto, es utilizado como control.
- Las propuestas A-PLRT y PrA-PLRT están rankeadas en las últimas posiciones por el test de Friedman, puesto que requieren mayor tiempo de CPU dado que deben tener en cuenta la sub-solución al problema en cada uno de los nodos del árbol.
- Los resultados del post-hoc test revelan que los métodos F-IBPLR y PrE-PLRT no muestran diferencia estadística significativa con respecto al algoritmo T-IBPLR.

Cabe destacar que, en este caso, el número de instancias en la mayoría de los conjuntos de datos utilizados es pequeño. No obstante, como puede observarse en la Tabla IV, para los conjuntos de datos con un número de instancias (considerablemente) grande, el algoritmo T-IBPLR no puede almacenar todas las distancias (por lo que no acaba) y el algoritmo F-IBPLR requiere de un gran tiempo de CPU. Por tanto, si hubiéramos utilizado (en su mayoría) conjuntos de datos con un alto número de instancias, el análisis llevado a cabo en términos de tiempo mostraría resultados más favorables para nuestras propuestas basadas en árboles de decisión, pues estas escalan mejor que los algoritmos basados en el paradigma de los vecinos más cercanos al crecimiento en el número de instancias de los conjuntos de datos.

## V. CONCLUSIONES

En este trabajo hemos planteado un nuevo problema para label ranking, en el que las instancias tanto del conjunto de entrenamiento como de test están etiquetadas con rankings completos y parciales.

Basándonos en [3], hemos decidido diseñar algoritmos basados en el paradigma de los vecinos más próximos (IBPLR) y en árboles de clasificación/regresión, teniendo que lidiar con el problema de no disponer de una distribución de probabilidad para rankings completos y parciales.

Atendiendo a esto, hemos adaptado el algoritmo IBLR al problema planteado, que hemos denotado como IBPLR, y hemos diseñado dos alternativas para PLRT, una teniendo en cuenta la sub-solución al problema en el nodo correspondiente y otra sin tener en cuenta dicha sub-solución.

De la evaluación experimental, podemos concluir que el clasificador de PLRT usando el criterio de entropía con y sin pre-poda es competitivo con el clasificador IBPLR en términos de precisión. Por otro lado, el rendimiento en términos de precisión para el clasificador PLRT usando desacuerdo como criterio, está por debajo del ofrecido por los anteriores, a pesar de tener en cuenta la sub-solución al problema en el nodo correspondiente. No obstante, cabe destacar que este último no presenta malos resultados en términos del coeficiente de correlación de rankings  $\tau_X$ .

En cuanto a tiempo, el rendimiento del clasificador IBPLR pre-calculando las distancias está por encima del resto de clasificadores. No obstante, como ya se comentó, si el número de instancias en los conjuntos de datos es considerablemente

grande, el clasificador IBPLR pre-calculando las distancias puede que no disponga de memoria suficientemente mientras que sin pre-cálculo el tiempo requerido es excesivo.

Como trabajo futuro, planteamos un enfoque más flexible en el que se permita que los conjuntos de datos estén etiquetados con rankings parciales, posiblemente incompletos. Además, para reducir el tiempo de inducción en los clasificadores PLRT, planteamos diseñar clasificadores débiles, que, para mejorar la precisión, se combinen en multi-clasificador (p.e., bosques aleatorios). También, para tratar de seguir la metodología propuesta en [3], planteamos estudiar una distribución de probabilidad para modelar bucket orders. Por último, pensamos que una posible área de aplicación del PLR sería en el campo del meta-aprendizaje, para recomendar los clasificadores apropiados a un conjunto de datos determinado, en función de sus características.

## AGRADECIMIENTOS

Este artículo ha sido parcialmente financiado por fondos FEDER y la Agencia Estatal de Investigación (AEI/MINECO) mediante el proyecto TIN2016-77902-C3-1-P.

## REFERENCIAS

- [1] R. Duda, P. Hart, and D. Stork, *Pattern Classification (2nd Edition)*. Wiley-Interscience, 2000.
- [2] J. Hernández-González, I. Inza, and J. Lozano, "Weak supervision and other non-standard classification problems: A taxonomy," *Recognition Letters*, vol. 69, pp. 49–55, 2002.
- [3] W. Cheng, J. Hühn, and E. Hüllermeier, "Decision tree and instance-based learning for label ranking," in *Proceedings of the 26th Annual International Conference on Machine Learning*. ACM, 2009, pp. 161–168.
- [4] S. Lin, "Rank aggregation methods," *Wiley Interdisciplinary Reviews: Computational Statistics*, vol. 2, pp. 555–570, 2010.
- [5] A. Gionis, H. Mannila, K. Puolamäki, and A. Ukkonen, "Algorithms for Discovering Bucket Orders from Data," in *Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2006, pp. 561–566.
- [6] J. Aledo, J. Gámez, and A. Rosete, "Utopia in the solution of the Bucket Order Problem," *Decision Support Systems*, vol. 97, pp. 69–80, 2017.
- [7] J. Aledo, J. Gámez, and D. Molina, "Tackling the supervised label ranking problem by bagging weak learners," *Information Fusion*, vol. 35, pp. 38 – 50, 2017.
- [8] C. de Sá, C. Soares, A. Knobbe, and P. Cortez, "Label ranking forests," *Expert Systems*, vol. 34, no. 1, 2017.
- [9] P. Emerson, "The original Borda count and partial voting," *Social Choice and Welfare*, vol. 40, no. 2, pp. 353–358, 2013.
- [10] J. Alfaro, "Label ranking classifiers to deal with partial rankings," Undergraduate Dissertation, School of Computer Science and Engineering, University of Castilla-La Mancha, 2018.
- [11] D. Dheeru and E. Karra, "UCI machine learning repository," <http://archive.ics.uci.edu/ml/>, 1987, online. Last accessed: September 4, 2018.
- [12] E. Emond and D. Mason, "A new rank correlation coefficient with application to the consensus ranking problem," *Journal of Multi-Criteria Decision Analysis*, vol. 11, pp. 17–28, 2002.
- [13] J. Demšar, "Statistical Comparisons of Classifiers over Multiple Data Sets," *J. Mach. Learn. Res.*, vol. 7, pp. 1–30, 2006.
- [14] S. García and F. Herrera, "An Extension on "Statistical Comparisons of Classifiers over Multiple Data Sets" for all Pairwise Comparisons," *Journal of Machine Learning Research*, vol. 9, pp. 2677–2694, 2008.
- [15] J. Arias and J. Cózar, "ExReport: Fast, reliable and elegant reproducible research," <http://exreport.jarias.es/>, 2015, online. Last accessed: September 4, 2018.
- [16] M. Friedman, "A comparison of alternative tests of significance for the problem of m rankings," *Ann. Math. Statist.*, vol. 11, pp. 86–92, 1940.
- [17] S. Holm, "A Simple Sequentially Rejective Multiple Test Procedure," *Scandinavian Journal of Statistics*, vol. 6, pp. 65–70, 1979.



# Fault predictive model for HVAC Systems in the context of Industry 4.0

Inés Sittón-Candanedo  
BISITE Digital Innovation HUB  
University of Salamanca  
Salamanca, Spain  
isittonc@usal.es

Elena Hernández-Nieves  
BISITE Digital Innovation HUB  
University of Salamanca  
Salamanca, Spain

Sara Rodríguez-González  
BISITE, Digital Innovation HUB  
University of Salamanca  
Salamanca, Spain

Fernando de la Prieta-Pintado  
BISITE Digital Innovation HUB  
University of Salamanca  
Salamanca, Spain

Juan Manuel Corchado-Rodríguez<sup>1,2,3</sup>

<sup>1</sup>Bisite Digital Innovation HUB  
University of Salamanca, Spain  
<sup>2</sup>Osaka Institute of Technology,  
Osaka, Japan  
<sup>3</sup>University Malaysia Kelantan,  
Kelantan, Malaysia

**Abstract**—Fault prediction has gained importance with Industry 4.0 paradigm. Nations, universities and several companies be research in this topic with the aim to optimize manufacturing process and reduce cost of equipment maintenance through create predictive models. The Heating, Ventilation and Air Conditioning Systems (HVAC) control in an important number of industries: in-door climate, air's temperature, humidity and pressure, creating an optimal production environment. In this paper, the use of some machine learnings algorithms applied to HVAC System data set are review as an instrument for evaluate a fault predictive model.

**Keywords**—Fault prediction; HVAC Systems; Industry 4.0; Machine Learning, Logistic Resregion, Decision Trees.

## I. INTRODUCTION

The development of automated models for the detection and diagnosis of faults in Heating, Ventilation and Air Conditioning Systems (HVAC) has been the subject of continuous research for many years. These researches have been developed for different reasons such as [1]:

- The continuous increase in energy costs;
- The interest of organizations in reducing their operations budgets;
- Reducing maintenance costs and equipment downtime;
- Avoiding production stoppages in factories that must maintain a standard temperature due to quality controls.

Heating, Ventilation and Air Conditioning Systems (HVAC) are an important component not only in residential buildings, also in industrials where it have an important role because their faults can produce an industry downtime. [2] Therefore, an oportune fault conditions recognition such as: (i) malfunctions in air distribution; (ii) very high, low or extreme temperature; (iii) inappropriate air distribution for

several periods of time and others can help to prevent the increase of maintenance, energy or production costs.

In 2000, Norford, Wright, Buswell, and Luo developed important researches about the importance of implementing fault detection and diagnosis system in industrial HVAC equipment's to increase equipment performance and durability. Norford, L., *et al.*, indicate that the use of automated algorithms can reduce the delay in fault detection, prevent downtime and correct equipment inefficiencies [3].

Since 2011 Industry 4.0 is using to define the new concept of factories in which manufacturing process is supervised by sensors and autonomous systems. These news ideas are affected important disciplines such as: (i) system, mechanical, industrial and electrical engineering; (ii) computer science; (iii) business information and administration [4]

The strengthening of these disciplines and emerging technologies have renewed the interest of researchers in universities, companies and government institutes. Currently, there is a great interest in the development of projects on automated systems that incorporate technologies for predictive analysis, oriented to the industrial sector.

One of the indicators of Industry 4.0 is the sensorization of the machines or equipment that are part of the infrastructure of the factory and the production process. In this sense, performance optimization is based on the ability to connect them to a data network. [5], [6].

In this technological context, the purpose of this papers is to use techniques and tools for the development of models capable of predicting future events, failures or behaviors. The prediction models proposed are built using statistical techniques, machine learning (ML) or data mining with which you can extract existing patterns in the data set that is analyzed. Allowing to obtain useful information for decision making processes, improving among other things; predictions and the anticipation of errors or failures in equipment, inherent risks in the production, production and expected sales volume [7]. However, these actions are linked to the processing of an overwhelming amount of data, which constitutes a challenge [8].

This document is divided as follows: the second section provides a summary of Industry 4.0, predictive maintenance, the application of machine learning (ML) in the context of Industry 4.0 and the prediction of failures. Then the case study is described and finally the results that show the accuracy of the algorithms and ML techniques applied to the conclusion and the lines of future work are presented.

## II. BACKGROUND

### A. Industry 4.0

The genesis of the Industry 4.0 concept is linked to the joint efforts that took place in Germany during the year 2011, where the government and the business sector led by the Bosch Company, formed a research group with the purpose of establishing a common framework that allowed the application of new technologies. This would imply significant improvements to the productive sectors of the country. The first group report was delivered in 2012 and was publicly presented in 2013 at the Hannover Fair [9].

With this initiative of the German government emerge what is known as the fourth industrial revolution, which other countries have decided to promote with names such as: Smart Manufacturing, Smart Production, Industrial Internet, i4.0, Connected Industry 4.0, to identify everything that encompasses the paradigm. The adoption of industry 4.0 is related to a set of technological enablers such as: IoT, CPS, Big Data, Wireless Sensor Networks (WSN) and Cyber physical systems (CPS) [2]. The IoT being one of the ones that provides the greatest support and influence.

### B. Internet of things

About the IoT, there is no standard definition universally accepted. However, the ITU (International Telecommunication Union) and the IERC (Internet of Things European Research Cluster) define it as: "a global and dynamic network infrastructure with the self-configuration of the capabilities based on protocols of standard and interoperable communication, where physical and virtual "things" have identity, physical attributes, virtual personalities and use intelligent interfaces that integrate seamlessly into the information network" [9][10].

The IoT or Internet of Things has become a fundamental element for the business sector within the context industry 4.0. This technology is the basis for generating great growth and increasing the indices of productivity and competitiveness [11].

The technological infrastructure that makes up the physical facilities of factories in the industry 4.0 model use control systems that share information among them, and these in turn apply the necessary changes, based on the data generated in the form of alerts or warnings. Subsequently commands or orders are sent to slave teams to modify the production process, thus preventing the production lines from stopping, which would generate losses in time and money. On the other hand, human operators can use the data obtained to properly

manage the conditions of the equipment and significantly increase the efficiency and effectiveness of the processes.

Another aspect that brings IoT technology to the technological current of Industry 4.0 lies in the possibilities of communication in real time between the business (factory), suppliers and customers. This will achieve a better business-supplier relationship, which would ultimately guarantee meeting the demands of a market composed of highly critical and demanding customers [12].

### C. Machine Learning for prediction

The Automatic Learning (ML) is a technology that already has several years of being used in the computer field. However, recently it is when it has gained great importance thanks to the advances in other technological areas such as the IoT. Initially it was used in the research for the search and identification of patterns, to get computers to learn [14].

According to Mitchell (2006) of Carnegie Mellon University, Machine Learning answers the question "How can we build computer systems that automatically improve with experience, and what are the fundamental laws that govern all learning processes?" [13]

Therefore, universities, research centers and industries have identify the enormous potential of this technology, transcending its use to a wide variety of areas such as neuroscience, health or economics. This has directly impacted the development of applications that allow us to solve not only the processing of large volumes of data from the Internet of Things and Big Data, but also to provide new information by extracting patterns and building predictive models, with automatic learning algorithms (ML) [15].

There are several types of algorithms based on machine learning (ML) that are grouped in supervised or not. Exist some classification criteria which divide them into others categories such as: decision tree, grouping or regression. However, something that is common to all these algorithms is the existence of components such as: representation, evaluation and optimization, figure 1 [14].



Figure 1. Components of learning algorithms.

In their jobs Murphy, 2012 and Michell, 1997 established that machine learning techniques emulate human cognition and learn with the aim to training and predict future events in more complex cases. In a brief review makes by [16] about more



common machine learning methods used in fault detection of HVAC Systems the most frequently are:

- Neural networks (NN) to predict, classify or control future problems (Bansal et al., 2015, Taylor 1996, Mehrotra 1997, Fausett 1994, Freeman 1993).
- Multilayer perceptron (Ruck et al, 1990)
- K-nearest neighbours (Denoeux, 1995)
- Naïve Bayes where the predictor is independent and makes an efficiently classification that is easy to interpret (Panda and Patra, 2007)
- Linear regression (Daniel, 2011) to predict the next failures.
- Artificial Neural Networks (ANN) for faults filters (Delgrange et al., 1998).

### III. INDUSTRY 4.0 ENVIRONMENT CASE STUDY

In this case study, a structured data set was used columnar. The data includes the optimal temperature and the real values captured by sensors located in buildings, to analyze how HVAC air conditioning systems behave. With this, it can be determined if the analyzed equipment is failing by not maintaining the lower temperatures in an optimal range of values.

Heating, ventilation and air conditioning (HVAC) systems control the internal climate, air temperature, humidity and pressure, creating an optimal production environment in industrial buildings. These equipment's are of great importance for the operation of a factory. However, maintenance routinely does not always clearly identify its faults. In this sense, the purpose of implementing a predictive maintenance for infrastructures of industry 4.0, would be to extend the useful life of the equipment using different tools and techniques to identify abnormal patterns such as: vibration, temperature or balance [17].

Following section describes a free dataset from temperature sensors installed on Heating, Ventilation and Air Conditioning System (HVAC) in 20 buildings [18].

#### 3.1 Dataset Description

This dataset contains a total of 8000 (eight thousand) temperature records (TargetTemp) captured by a sensor network, installed in a set of buildings who were between 0 and 30 years old, their age corresponded to age of the HVAC systems. Table I shows the name of dataset attributes and their description.

TABLE I. DESCRIPTION OF DATASET ATTRIBUTE

Attribute	Description
Date	Date of measurement
Time	Measurement time
TargetTemp	Temperature measured by the sensor

Attribute	Description
Actualtemp	Optimal temperature for the system
System	System Model
SystemAge	Age of the HVAC System
BuildingID	Building Identifier

#### 3.2 Pre-processed

For preprocessing, a range was established for normal temperatures and two types of alarms that indicate extreme temperatures and, therefore, a possible failure. These are described in figure 2 as follows:

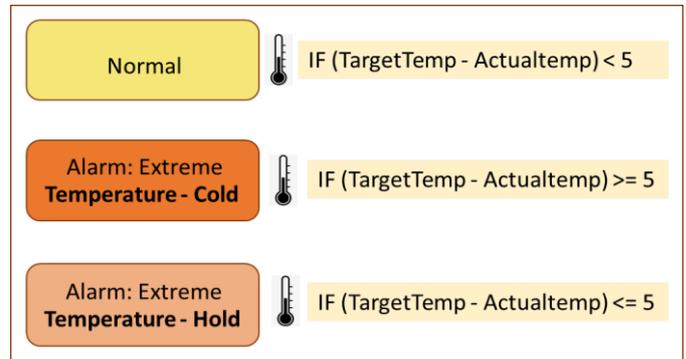


Figure 2. Conditions to determine normal and extreme temperature.

Two labels are added to the dataset 'Difference' and 'FilterDifference', in the first, the values obtained from the difference between 'TargetTemp' and 'Actualtemp' are stored. In 'FilterDifference' the binary conversion is carried out assigning 0 to the normal temperatures and 1 to the alarms for extreme temperature.

#### 3.3 Training and results

Once the data were pre-processed, the extended dataset was used to divide the data into data train and data\_test, the former was used to apply Machine Learning algorithms to obtain the prediction model. This model was then validated with the data\_test. For the training of the data, two supervised learning algorithms will be used: Logistic Regression and Decision trees to evaluate the accuracy of each one in the prediction.

Logistic regression is a machine learning technique, statistical-inferential, which dates to the 1960s, used in current scientific research. It is considered an extension of linear regression models, the difference is that it has a categorical variable capable of being binomial (0, 1) or multiple [19][20]. For the development of this research, the dataset was pre-processed so that the categorical variable (y) can be binomial. Applying the logistic regression analysis, we assume that  $y = 1$ , when the sensor sends an extreme temperature and  $y=0$  when the measured temperature ('TargetTemp') is within the normal range. Considering the above, the probability that the HVAC system is presenting a failure by recording extreme temperatures is given in equation 1:

$$P(y = 0) = 1 - P(y = 1) \quad (1)$$

$$Y = f(B_0 + B_1X_1 + B_2X_2 + \dots + B_nX_n) + u \quad (2)$$

Where  $u$  is the error term and  $f$  the logistic function:

$$f(z) = \frac{e^z}{1+e^z} \quad (3)$$

So, that:

$$E[Y] = P = P(Y = 1) = \frac{e^{B_0+B_1X_1 + B_2X_2+\dots + B_nX_n}}{1+e^{B_0+B_1X_1 + B_2X_2+\dots + B_nX_n}} \quad (4)$$

$$\ln\left(\frac{P}{1-P}\right) = B_0X_0 + B_1X_1 + B_2X_2 + \dots + B_nX_n \quad (5)$$

Decision trees (DT) can be described as the combination of mathematical and computational techniques that allow us to understand the importance of the attributes of the description, categorization and generalization of a particular set of data. On the other hand, it is one of the most successful techniques for supervised learning through classification [21][22].

Through DT the data that will be analyzed can be expressed in the following way:  $(x, Y) = (x_1, x_2, \dots, x_n, Y)$ . The dependent variable,  $Y$ , is the objective variable that must be understood, classified or generalized (FilterDifference, in our case). The vector  $x$  is composed of the input variables (or attributes)  $x_1, x_2, x_3$ , etc., that are used for that task. The DT is formed through the following steps [21].

- a. Define the regression deviation of a node, as expressed in equation 6.

$$D(I) = \sum_{j=1}^{I_k} (y_{I_j} - \bar{y}_I)^2 \quad (6)$$

Where:

$y_{I_1}, y_{I_2} \dots y_{I_k}$  are the values of the target variable that compose the node  $I$ , and  $\bar{y}_I$  is their average [20]

- b. Prune the tree removing divisions from bottom to top, equation 7.

$$D_T(\alpha) = D_T + \alpha |T| \quad (7)$$

Where  $|T|$  is the number of terminal nodes and  $\alpha$  is a penalty term which ensures the greatest compromise between predictive accuracy and tree size [21].

The evaluation of a prediction model can be done according to different aspects. Therefore, for this research, authors use the accuracy, ROC curve and Spearman's Rho to evaluate the best

model. Spearman's Rho is a measure of the relation between two variables. In this case  $X = \text{SystemAge}$  and  $Y = \text{FilterDifference}$  as categorical variable. It is defined in equation (8). Spearman's Rho take values between -1 to 1 where higher values indicated a better model.

$$r_s = \text{COV}(r_{g_x}, r_{g_y}) / \sigma_{r_{g_x}} \sigma_{r_{g_y}} \quad (8)$$

In other hand, to obtain the accuracy a confusion matrix was made using equation 9

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad (9)$$

Where:

- TP = True Positive
- FN = False Negative
- FP = False Positive
- TN = True Negative

In the case of Receiver Operation Curve (ROC) the area under the curve can be interpreted as the probability that before a pair of binary values, one represents the failure and the other does not, the test classifies them correctly [23]. The BigML platform was used to generate Receiver Operation Curve (ROC) and the results show in the next section. This tool permit analyzes real data set to build machine learning predictive models.

#### IV. RESULTS AND DISCUSSION

In this research two supervised machine learning algorithms was tested for identify abnormal behavior. They were described in section 3.3., with the training process.

After the training phase, the logistic regression and decision tress algorithms enter in a test phase. The 8000 instances that make up the dataset were divided, taking 70% for training and 30% for test data. The SystemAge column was taken as a characteristic and, as a label, the FilterDifference column, the total of instances was 8000. The evaluation of the model generated an accuracy of 66.9%. To calculate it, equation 9 was used.

After computers, the Spearman's Rho between the ranked actual values of the instances and the model predictions, with logistic regression, the Spearman's Rho was 0.0132. It indicated a better model. Figure 4 is the graph for this model. The ROC AUCH was 0.5557.

The logistic regression model used in this article compares between the categorical variable and a set of independent or predictive variables. In this phase to identify the attributes that most contribute to predict a failure three variables were exposed to linear regression analysis with the BigML platform.

In this paper we also show how the use of a decision tree can greatly reduce the occurrence of false positives or negatives.

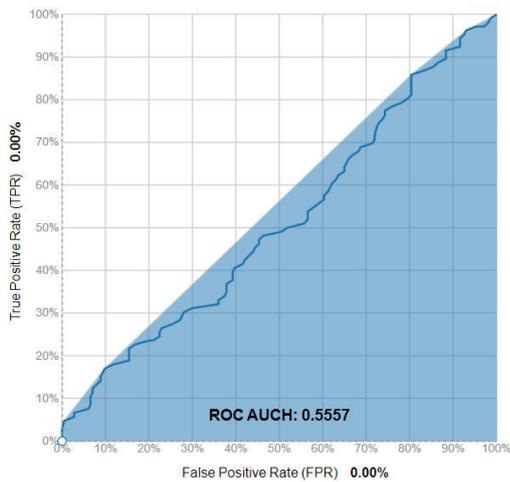


Figure 4. Area under ROC curve with the logistic regression model.

After applying the logistic regression model and obtaining its percentage of precision, the decision tree model was applied to the data set. The results are shown graphically (confusion matrix and the ROC graph) in figure 5. The evaluation of the model provided a precision percentage of 64.2%.

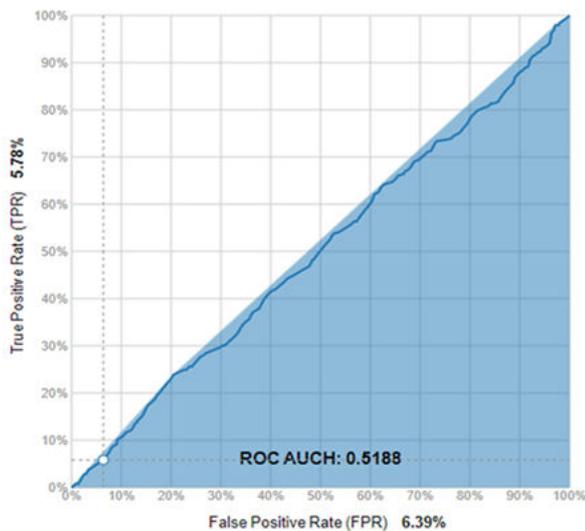


Figure 5. Area under ROC curve with the decision tree model.

## V. CONCLUSIONS AND FUTURE WORK

This work presents two machine learning algorithms used to predict faults in HVAC System.

The proposed prediction model still in its early stage of development. This allows for the implementation of other machine learning techniques and for the use of larger datasets obtained from sensors networks installed in order environment. The results for the dataset used in this case study, show that the precision of the logistic regression model is similar to that of

decision tree model, in predicting malfunction in the HVAC system.

The modeling and integration of the large volumes of industrial data that are generated by machines and collected by sensors, is a clear problem that still needs to be addressed in future researches. Thus, testing with other machine learning methods for classification, training and prediction. These test will provide the grounds for the development of algorithms that generate predictive models adapted for organizations, in the context of industry 4.0.

As future work it is possible to conduct additional studies using other techniques to compare and identify the best performing predictive approach for HVAC systems.

## ACKNOWLEDGMENT

This work was supported by the Spanish Ministry of Economy and FEDER funds. Project. SURF: Intelligent System for integrated and sustainable management of urban fleets TIN2015-65515-C4-3-R.

I. Sittón-Candanedo has been supported by IFARHU – SENACYT scholarship program (Government of Panama).

## REFERENCES

- [1] House, John M.; LEE, Won Yong; SHIN, Dong Ryul. Classification techniques for fault detection and diagnosis of an air-handling unit. *ASHRAE Transactions*, vol. 105, p. 1087, 1999.
- [2] Perez-Lombard, L., Ortiz, J., Pout, C., "A review on buildings energy consumption information, *Energy Build*, 40(3), 394-398, 2008.
- [3] Norford, L. K., et al. Final report of ASHRAE Research Project 1020-RP: Demonstration of fault detection and diagnosis in real a building. Massachusetts Institute of Technology and Loughborough University, 2000.
- [4] Kagerman, H., Anderl, R., Gausemeier J., Schuh G., and Wahlster W. "Industrie 4.0 in a Global Context: Strategies for Cooperating with International Partners", Acatech Study, Munich, Germany. <https://www.acatech>, 2016.
- [5] Rivas, A., Martín, L., Sittón, I., Chamoso, P., Martín-Limorti, J. J., Prieto, J., & González-Briones, A. Semantic Analysis System for Industry 4.0. In *International Conference on Knowledge Management in Organizations* (pp. 537-548). Springer, Cham, 2018.
- [6] Kuo, C. J., Ting, K. C., Chen, Y. C., Yang, D. L., & Chen, H. M., "Automatic machine status prediction in the era of Industry 4.0: Case study of machines in a spring factory". In: *Journal of Systems Architecture*, Vol., 81, 44-53, 2017.
- [7] Bishop, C.M., "Pattern recognition and machine learning". Springer, New York, Vol. 4, doi:10.1171/1.2819119, 2006.
- [8] Civerchia, F., Bocchino, S., Salvadori, C., Rossi, E., Maggiani, L., and Petracca, M., "In-dustrial Internet of Things Monitoring Solution for Advanced Predictive Maintenance Applications". In: *Journal of Industrial Information Integration*, 2017.
- [9] Hermann, Mario; Pentek, Tobias; Otto, Boris. Design principles for industrie 4.0 scenarios. In *System Sciences (HICSS)*, 49th Hawaii International Conference on. IEEE, 2016. p. 3928-3937, 2016.
- [10] Li, Zhe; Wang, Yi; Wang, Ke-Sheng. Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. *Advances in Manufacturing*, 2017, vol. 5, no 4, p. 377-387.
- [11] Brettel, M., Friederichsen, N., Keller, M., & Rosenberg, M. (2014). How virtualization, decentralization and network building change the

- manufacturing landscape: An Industry 4.0 Perspective. *International Journal of Mechanical, Industrial Science and Engineering*, 8(1), 37-44.
- [12] Xu, L. D., Xu, E. L., & Li, L. (2018). Industry 4.0: state of the art and future trends. *International Journal of Production Research*, 56(8), 2941-2962.
- [13] Mitchell, T. M. (2006). *The discipline of machine learning* (Vol. 9). Carnegie Mellon University, School of Computer Science, Machine Learning Department.
- [14] Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87.
- [15] Al-Jarrah, O. Y., Yoo, P. D., Muhaidat, S., Karagiannidis, G. K., & Taha, K. "Efficient machine learning for big data: A review". In: *Big Data Research*, Vol., 2(3), 87-93, 2015.
- [16] Tehrani, Mahdi Mohammadi, et al. A predictive preference model for maintenance of a heating ventilating and air conditioning system. *IFAC-PapersOnLine*, vol. 48, no 3, p. 130-135, 2015.
- [17] Verbert, K., Babuška, R., De Schutter, B. "Combining knowledge and historical data for system-level fault diagnosis of HVAC systems". In: *Engineering Applications of Artificial Intelligence*, Vol., 59, 260-273, 2017.
- [18] Hortonworks, "Analyze HVAC Machine and sensor data". <https://es.hortonworks.com/ha-doop-tutorial/how-to-analyze-machine-and-sensor-data/#section-2>. 2017.
- [19] De Menezes, F. S., Liska, G. R., Cirillo, M. A., & Vivanco, M. J., "Data classification with binary response through the Boosting algorithm and logistic regression". In: *Expert Systems with Applications*, Vol., 69, 62-73, 2017.
- [20] Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X., "*Applied logistic regression*". Editorial: John Wiley & Sons, Second Edition, p. 500, 2013. ISBN 978-0-470-58247-3.
- [21] Lin, L. H., Chen, K. K., & Chiu, R. H. (2017). Predicting customer retention likelihood in the container shipping industry through the decision tree approach. *Journal of Marine Science and Technology*, 25(1), 23-33.
- [22] Liu, X., Li, Q., Li, T., & Chen, D. (2018). Differentially private classification with decision tree ensemble. *Applied Soft Computing*, 62, 807-816.
- [23] Bradley, Andrew P. "The use of the area under the ROC curve in the evaluation of machine learning algorithms." *Pattern recognition* 30.7 (1997): 1145-1159.

**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 2:  
SISTEMAS DE  
RECOMENDACIONES







# Neighbor selection for cold users in collaborative filtering with positive-only feedback\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Alejandro Bellogín  
*Universidad Autónoma de Madrid*  
Madrid, Spain  
alejandro.bellogin@uam.es

Ignacio Fernández-Tobías  
*NTENT*  
Barcelona, Spain  
ifernandez@ntent.com

Iván Cantador  
*Universidad Autónoma de Madrid*  
Madrid, Spain  
ivan.cantador@uam.es

Paolo Tomeo  
*Politecnico di Bari*  
Bari, Italy  
paolo.tomeo@poliba.it

**Abstract**—Recommender systems heavily rely on the availability of historical user preference data, struggling to provide relevant suggestions for new users. The cold start user scenario is thus recognized as one of the most challenging problems in the recommender systems research area. Previous work has focused on exploiting additional information about users and items –e.g., user personality and item metadata– to mitigate the lack of user feedback. However, it is still unclear how to approach the worst scenario where no side information is available to a recommender system. Addressing this problem, in this paper we focus on new users of memory-based collaborative filtering methods with positive-only feedback, and conduct a comprehensive study of a number of neighbor selection strategies. Specifically, we present empirical results on several datasets analyzing the effects of choosing adequately the user similarity, the set of candidate neighbors, and the size of the user neighborhoods. In particular, we show that even few but reliable neighbors lead to better recommendations than large neighborhoods where cold start users belong to.

**Index Terms**—recommender systems, collaborative filtering, cold start, neighbor selection



# PMSC-UGR: A test collection for expert recommendation based on PubMed and Scopus\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

César Albusac, Luis M. de Campos, Juan M. Fernández-Luna, Juan F. Huete  
*Departamento de Ciencias de la Computación e Inteligencia Artificial*  
*Universidad de Granada*  
Granada, Spain  
calbusac@ugr.es, {lci, jmfluna, jhg}@decsai.ugr.es

**Abstract**—A new test document collection, PMSC-UGR, is presented in this paper. It has been built using a large subset of MEDLINE/PubMed scientific articles, which have been subjected to a disambiguation process to identify unequivocally who are their authors (using ORCID). The collection has also been completed by adding citations to these articles available through Scopus/Elsevier’s API. Although this test collection can be used for different purposes, we focus here on its use for expert recommendation and document filtering, reporting some preliminary experiments and their results.

**Index Terms**—Test collection, Authors disambiguation, Expert finding, Document filtering, MEDLINE/PubMed, Scopus



# An Intelligent Advisor for City Traffic Policies\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Daniel H. Stolfi, Christian Cintrano, Francisco Chicano, Enrique Alba

*Departamento de Lenguajes y Ciencias de la Computación*

*University of Málaga*

Málaga, Spain

{dhstolfi,cintrano,chicano,ea}@lcc.uma.es

**Abstract**—Nowadays, city streets are populated not only by private vehicles but also by public transport, fleets of workers, and deliveries. Since each vehicle class has a maximum cargo capacity, we study in this article how authorities could improve the road traffic by endorsing long term policies to change the different vehicle proportions: sedans, minivans, full size vans, trucks, and motorbikes, without losing the ability of moving cargo throughout the city. We have performed our study in a realistic scenario (map, road traffic characteristics, and number of vehicles) of the city of Malaga and captured the many details into the SUMO microsimulator. After analyzing the relationship between travel times, emissions, and fuel consumption, we have defined a multiobjective optimization problem to be solved, so as to minimize these city metrics. Our results provide a scientific evidence that we can improve the delivery of goods in the city by reducing the number of heavy duty vehicles and fostering the use of vans instead.

**Index Terms**—Application, evolutionary algorithm, road traffic, city policy, real world, smart mobility



**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 3:  
NAVEGACIÓN Y  
SMART CITIES







# Analysis of Sensor Fusion Solutions for UAV Platforms

Jesus Garcia

Universidad Carlos III  
Applied Artificial Intelligence Group  
Madrid, Spain  
jgherrer@inf.uc3m.es

Jose M. Molina

Universidad Carlos III  
Applied Artificial Intelligence Group  
Madrid, Spain  
molina@ia.uc3m.es

**Abstract**—Evaluation of Unmanned Aerial Vehicle (UAV) systems is mostly based on simulation tools that are manually configured to analyse the system output. In this work, the authors present an original method to evaluate the performance of UAV platform in real situations based on available data. The main innovation is an evaluation for designing sensor fusion parameters using real performance indicators of accuracy of navigation in UAVs based on PixHawk flight controller and peripherals. This platform allows physical integration of the main types of sensors in UAV domain, and at the same time the use of powerful simulation models developed with Gazebo. This methodology and selected performance indicators allows to select the best parameters for the fusion system of a determined configuration of sensors and a predefined real mission.

**Keywords**— UAVs sensor fusion, EKF, Real Data Analysis, System Design.

## I. INTRODUCTION

Unmanned vehicles must be able to control their attitude and position by means of automatic control algorithms, they are controlled by a computer that integrates data from some electro-mechanical sensors and any local or global positioning system and applies any output control system to change its location using any locomotion system. The controller usually is an embedded microcontroller with appropriate interfaces to all vehicle components. As an example, PixHawk Px4 system integrates navigation data and software modules including fusion algorithms [1].

The main problem in navigation focuses on improving GPS with the ability to provide accurate navigation output when GPS data becomes unavailable due to unexpected outages or intentional problems (jamming or spoofing) in certain environments. Therefore, an approach based on the fusion of complementary sensors is essential, resorting to the fundamental equations of navigation and the characterization of the errors committed by each data source. This area has become popular due to the ubiquity of GPS and the availability of inertial sensors based on inexpensive MEMS components [2], [3], [4]. The integration of these complementary technologies allows compact and robust navigation solutions to determine attitude and location, so that the vehicle can determine its state in a robust way and use appropriate control techniques for autonomy. Other more drastic options for non-dependence on the GPS signal

involve the deployment of autonomous localization systems such as the recognition of the environment by artificial vision [5] or location by means of electromagnetic beacons [6], with the associated cost of developing a complementary infrastructure.

Complementary to navigation technologies, the use of lasers in combination with other range detection sensors (sonar, radar, video), allows to extend the navigation conditions and obstacle avoidance. In order to develop obstacle avoidance algorithms, it is interesting to include software simulation to carry out tests without incurring risks for people and devices. Gazebo is a powerful 3D simulation environment for autonomous vehicles that is particularly suitable for testing object-avoidance. Gazebo can be used with Software In Loop (SIL) and Hardware In Loop (HIL) design. However, the simulation software will be outside the scope of the document. In the air vehicles (UAVs), the integration requirements (consume, weight, dimensions) are much more restrictive but, even so, it is a line in continuous development [7],[8],[9].

Therefore, research of robust and general techniques to integrate complementary data sources has become essential for this type of systems. In addition to theoretical developments, it is of vital importance the availability of equipment and experimental environments to validate the robustness of the solutions working in real-world conditions. The integration of sensors has to be based on the definition of parameters of the tracking system that should be adjusted to improve performance in a predefined set of missions with a defined set of sensors. The methodology proposed in this paper assumes that real system adjustments will be based on a real platform with predefined flight missions so that, in this context, the best parameters could be obtained analyzing the real operation of sensors and real output. Simulation of UAV environments is a powerful tool but not enough to evaluate in a thorough way these systems in real conditions of real missions. Accordingly to [13], evaluation tasks should be aligned with the user needs and how the fusion system meets the specifications. The selection of parameters and quality metrics is a complex task, particularly in real applications, since there are not ground truth or a standard methodology for making the data fusion evaluation. There are numerous examples of output analysis of algorithms and configurations based on simulation, such as characterizing navigation errors [14], sensor fault detection [15], or sensor integration in maritime navigation domain [16]. Other works in

UAV navigation use experimental real data sets, usually in a single flight, in order to assess specific aspects such as robustness against GPS outages [17] or impact of outliers in different solutios [18].

This paper presents the selected platform, design tools and environment for real experimentation, the proposed methodology and a selection of available data sources and effects of data processing techniques on the quality of the navigation solution. The main contribution of this paper is the briefing of a methodology used for adapting filter parameters to real conditions, and further systematic analysis of available real data. Section II introduces the selected working platform, detailing the architecture of its software and the vehicles we have made to test its capacities and collect data. Section III presents the proposed methodology and evaluation metrics, section IV explains experimental environment and and analysis of the PixHawk Px4 system filter and fusion algorithms following the presented methodology. Finally, section V summarizes the conclusions derived from this work.

## II. THE PIXHAWK AND PX4 UAV SYSTEM

### A. Architecture

Unmanned vehicles must be able to control their attitude and position by means of automatic control algorithms. They are controlled by a computer that integrates data from some electro-mechanical sensors and any local or global positioning system, and applies any output control system to change its location using any locomotion system. This controller is usually an embedded microcontroller that performs the core of all vehicle components.

This research is based in the study of the PixHawk flight controller performance. An open-hardware computer designed by 3D Robotics specifically to create autopilot vehicles, that arises from the combination of PX4FMU and PX4IO boards. Both cards, from their version v2, are integrated in the same PCB (Printed Circuit Board) giving origin to PixHawk.

### B. Sensors and data sources

The PixHawk board has several sensors integrated, shown in Table I, which serve as data sources to the PX4 stack and include some processing functions:

TABLE I. SENSORS INTEGRATED IN THE PIXHAWK BOARD

Sensor	Type	Axes	Scale	ADC accuracy	Data rate
L3GD20H	gyroscope	3	2000 dps	16 bits	760 Hz
LSM303D	accelerometer/ magnetometer	6	$\pm 16g /$ $\pm 2\text{gauss}$	16 bits	1600 Hz/ 100 Hz
MPU-6000	accelerometer/ gyroscope	6	$\pm 16g /$ 2000 dps	16 bits	1000 Hz/ 8000 Hz
MS5611	barometer	1	1200 mbar	24 bits	1000 Hz

<sup>1</sup> www.nuttx.org

These sensors allow enhancing navigation capabilities and increase the accuracy of the stabilization system measurements, what is quite important when we want to create an unmanned vehicle, because allows a more faithful image of the flying environment.

### C. Software for Flight Control and Data Processing

PX4 is the control software of PixHawk processor. It is a real-time operating system based on NuttX<sup>1</sup> and consists of two main layers: PX4 Flight Stack and PX4 Middleware. PX4 Flight Stack is the complete collection of applications embedded in PixHawk hardware for drone control, while PX4 Middleware is the interface that allows the flow of data from sensors to applications through a publish/subscribe system called uORB. uORB allows to publish the data coming from the sensors and make them available to the applications of the Flight Stack, obtaining a reactive system and totally parallelized. The outstanding modules are flight controller and sensor data processing [19].

Regarding the data processing, Px4 implements an AHRS (attitude and heading reference system) that implements different algorithms to estimate the vehicle attitude and creates a direction vector that allows the unmanned displacement. In this section we will overview some basic algorithms that run into the system during the flights.

#### a) Direction Cosine Matrix (DCM)

This program allows the analysis of the triaxial accelerometers and gyroscopes data to obtain a Direction Cosine Matrix [20]. It makes possible the conversion of real-time measurements into instantaneous orientation parameters of the vehicle to deliver roll, pitch and yaw angles or variations:

#### b) Inertial Navigation System (INS)

This algorithm calculates the trajectories and corrections that allows the vehicle to move between single points using the DCM data. It is used to estimate the vehicle attitude with high frequency, so it is especially useful to complement the global position obtained from the GPS data.

#### c) Extended Kalman Filter (EKF)

All measurements are affected by noise that should be taken into account in the estimation of attitude and cinematic parameters. The Px4 system counts with several Extended Kalman Filter algorithms to process all sensor data in a compensation function that depends of the specific noise and accuracy characterization of each sensor, throwing high accuracy estimations of the vehicle attitude. The Px4 application counts with the possibility of applying different EKF solutions running in parallel, using different sensor measurements and states. With this implementation, it is possible to increase the accuracy and consistence of estimates even if the vehicle losses the GPS signal in certain time intervals. Table II shows the three different available EKF modes.

### D. Possibility of SIL and HIL design.



Pixhawk supports SIL [29] and HIL [30] using Gazebo simulation. This way, it is possible to debug navigation and object-avoidance algorithms in PixHawk flight controller, without using any real device. In this way, you could save on material cost, as well as increase the quality of the final product.

TABLE II. PX4 EXTENDED KALMAN FILTERS

Name	Specification
EKF1	Only use the DCM for attitude control and the Inertial navigation for AHRS reckoning for position control
EKF2	Use the GPS for 3D velocity and position. The GPS altitude could be used if barometer data is very noisy.
EKF3	If there is no GPS, it can use optical flow to estimate 3D velocity and position.

In addition, Gazebo offers various models of real autonomous vehicles, saving modeling time. In case of not being offered by Gazebo, it will be necessary to use time and resources in a correct physical modeling, so that the conditions of simulation could be as close as possible to reality. It will be the task of the engineer to evaluate the interest in using software simulation. Furthermore, it is necessary to keep in mind the fact that Software modeling and simulation is only of interest when it is carried out by an experienced engineer in the field. Otherwise, the behavior of the system would not be reproduced in a faithful manner.

Specifically, in the case of Pixhawk, a HIL configuration allows running the code written in the flight controller without using any real sensor. That fact allows a first contact in the study of the effect of the parameters of navigation and evasion algorithms.

### III. EVALUATION OF UAV SENSOR FUSION IN REAL CONDITIONS

In many real problems, simulated environments are used to define UAV sensors and the system parameters to optimize the system performance [14],[15],[16],[21],[22]. Some problems appear with this kind of methodologies, basically how to represent in simulation all effects appearing in real conditions and the way to evaluate the parameters configuration. UAV simulation have been applied to design the control subsystem for predefined missions, but simulation of real sensors is a major problem in this kind of approach. Real UAV conditions are not easy to model in simulators. UAV are affected for atmospheric conditions and random movements of UAV platforms, so accurate simulation of input data is extremely complicated for designing system parameters. As mentioned before, it would be necessary to evaluate advantages and disadvantages of using simulation environments.

In this scenario, the proposed methodology, depicted in Fig. 1, tries to test the system parameters under real conditions. The first step of this methodology is the definition of the UAV platform, the type, cinematic characteristics, set of sensors and the tracking algorithms. Once the UAV platform is defined, the methodology is composed by the following steps:

1.- Mission definition. Parameters are selected from a set of possible values for a specific mission, defined by means of several waypoints. These waypoints are used to repeat the same mission every time that a new evaluation is done.

2.- Each time a flight of the UAV passing through the predefined waypoints (mission) is carried out, the values of the sensor data are stored (position and velocity taken from GPS, inertial data, magnetometers, etc.)

3.- A set of flights, with the same waypoints defining the mission, are carried out and the corresponding sets of sensors data are stored together with system output, using several configurations of parameters for filtering. These values are postprocessed offline.

4.- The best configuration of parameters is selected, analyzing the performance metrics for the set of missions carried out over the same waypoints.

5.- The selected parameters are introduced in UAV system to perform real mission

The decision about “the best” parameters should be based in a set of indicators to evaluate the quality of the main components of the data fusion system. The validation and quality assessment of fusion system is a fundamental step in the development. However, as indicated in [23], the development of objective evaluation metrics with no available ground truth is a challenge yet for data fusion researchers. There are no well-established procedures to systematically evaluate sensor fusion systems beyond simulated conditions, making in many times difficult to predict performance in real-world conditions. After a revision of previous works, there are scarce global metrics without ground truth of fusion system, such as [24] where the metrics are fusion break rate, rate of fusion tracks and track recombination rate. This terminology considers “global” metrics as those assessing the global fusion system output, while “local” metrics evaluate specific outputs from individual sensor data processes in a decentralized fusion architecture. Some local metrics without ground truth are: rate of non-associated data, rate of premature deleted tracks and average residual [24], association performance metrics for track purity and track switches [25], or number of missed targets, track life time, rate of false alarms, rate of track fragmentation and track latency [26].

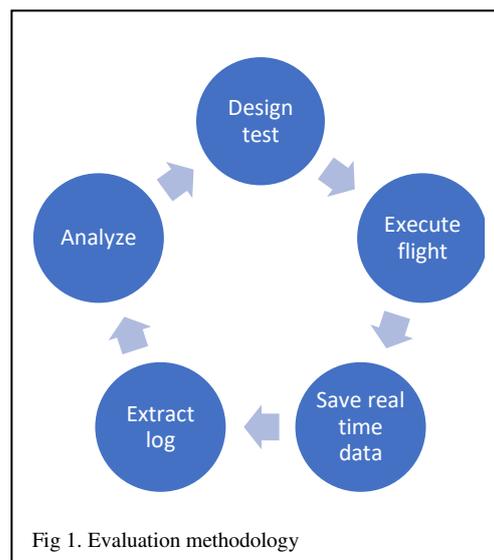


Fig 1. Evaluation methodology

TABLE III. TEST PERFORMED OVER THE SAME CIRCUIT

Name	Specification
Static test without propellers	Accelerometers and gyroscopes, noise.
Static test on ifle	Accelerometers and gyroscopes, noise
Unmanned flight test	GPS, inertial navigation system
Unmanned hold test	GPS, Flow Sensor, DCM
Manual flight test	PID and configuration parameters

In navigation function, since data association is not a problem (all sensor data associate to the vehicle track), the sensor fusion performance is evaluated with the following global indicators:

- averaged innovations
- fusion break rate

These metrics allow the validation of the designed system and decision of appropriate configuration parameters in complex scenarios.

1) *Averaged innovations*

The innovation, or residual, is computed in the tracking filter each time an update is done for the prediction. For instance, for horizontal XY position, denoting with sub-index p the predicted track and sub-index m for measurement, and considering the average along a time window with  $N_T$  measurements, it is defined as:

$$r = \frac{1}{N_T} \sum_{i,k} (\hat{x}_{pi}[k] - x_{mi}[k])^2 + (\hat{y}_{pi}[k] - y_{mi}[k])^2 \quad (1)$$

The normalized innovation also employs the covariance matrices considering both the predicted and observation uncertainties, matrix S. The averaged value of normalized innovations defined as:

$$r_n = \frac{1}{N_T} \sum_i \begin{bmatrix} \hat{x}_{pi}[k] - x_{mi}[k] & \hat{y}_{pi}[k] - y_{mi}[k] \end{bmatrix} S_i^{-1} \begin{bmatrix} \hat{x}_{pi}[k] - x_{mi}[k] \\ \hat{y}_{pi}[k] - y_{mi}[k] \end{bmatrix} \quad (2)$$

This value is a-dimensional, and represents the discrepancy between observations and predictions, averaged along the measurements contained in  $N_T$ .

Sometimes, if full covariance matrices are not available, a simplification is done and only the variances (diagonal terms) are considered:

$$r_n = \frac{1}{N_T} \sum_i \left( \frac{(\hat{x}_{pi}[k] - x_{mi}[k])^2}{\sigma_{xp}^2 + \sigma_{xm}^2} + \frac{(\hat{y}_{pi}[k] - y_{mi}[k])^2}{\sigma_{yp}^2 + \sigma_{ym}^2} \right) \quad (3)$$

2) *Fusion break rate*

The rate of fusion break,  $t_{FB}$ , is the number of times some navigation source is declared as inconsistent in the integrity analysis and therefore de-fused (the less consistent component is removed from the system track). This may lead to tracker re-initialization or keep the system track with a component less, the faulty sensor. It is computed as:

$$t_{FB} = \frac{\sum_i \{gt_i \mid gt_i \text{ is inconsistent track}\}}{N_T} \quad (4)$$

The value, averaged along  $N_T$  measurements, is obtained counting the total number of fusion break events during the interval. The test to decide the removal of a data source is done using the innovation, this time normalized by a higher number of standard deviations, typically 5.

IV. EXPERIMENTAL ENVIRONMENT AND EVALUATION OF TRACKING FILTERS FOR SENSOR FUSION

The process of data acquisition was based on several flight test missions that have taken place on circuits like the one sketched in Fig. 2. For each specified mission, we applied different configuration parameters to analyze the performance differences between each setting up of tracking filters. The flight controller log data was saved together with the configuration settings to be analyzed. For instance, table III, shows different tests carried out on the previous circuit and the analyzed elements of the navigation system (sensors and controllers). Remember, for information purposes that HIL strategy could be used in order to get simulated sensor data instead of real data.

The most typical task carried out by the data fusion process of the Pixhawk (EKF2 filter) is the attitude estimation using magnetometer, gyroscope and accelerometer data (attitude and heading reference system), and then fuse with accelerometers and GPS data to estimate position and velocity.

So, the sensor fusion system is based on a loosely coupled architecture which uses GPS position and velocity measurements to aid the INS, typically used in most of navigation solutions based on sensor fusion [15],[18],[19],[21],[28]. In this way, the IMU sensors are used extrapolate position, velocity, and attitude at high frequency (50 Hz), while updates from GPS measurements at low frequency (1 Hz) allows refinement of cinematic estimates and inertial sensor biases. Typically, the estimated state vector resulting in the output for the GNSS/INS filter contains the attitude vector represented with a quaternion, 3D position and velocity, three gyro biases and three accelerometer biases. The selected coordinate frame for position and velocity is the ENU frame (East, North, Down) with respect to the tangent plan with origin defined by the arming point in the start of the mission.

The EKF filter, used for sensor fusion in navigation, depends on two sets of parameters wick are sensor noise and plant noise. Both the estimation of cinematic parameters and sensor biases critically depend on the parameters characterizing noise in sensor data and uncertainty in prediction (process noise). Specificalcly, process noise parameters affect to the predicted error covariance and have critical impact in the weights given to the sensor observations with respect to the predicted estimates. A higher value for these parameters imply higher values of predicted covariance and so higher gain to observations (since the confidence on prediction decreases). Conversely, lower values imply lower gain to observations (higher confidence on predictions). The first set (sensor noise parameters) is usually given by accuracy tables from sensor providers.

TABLE IV. PROCESS NOISE PARAMETERS OF EKF

Name	Specification	Flight 1	Flight2	Flight3	Flight4	Flight5	Flight6
EKF2_ACC_B_NOISE	Process noise for IMU accel. bias prediction	0.003 m/s <sup>3</sup>	0.001 m/s <sup>3</sup>	0.003 m/s <sup>3</sup>	0.007 m/s <sup>3</sup>	0.01 m/s <sup>3</sup>	0.003 m/s <sup>3</sup>
EKF2_GYR_B_NOISE	Process noise for IMU rate gyro bias prediction	0.001 rad/s <sup>2</sup>	0.001 rad/s <sup>2</sup>	0.003 rad/s <sup>2</sup>	0.007 rad/s <sup>2</sup>	0.01 rad/s <sup>2</sup>	0.001 rad/s <sup>2</sup>
EKF2_ACC_NOISE	Accelerometer noise for covariance prediction	0.35 m/s/s	0.1 m/s/s	0.3 m/s/s	0.7 m/s/s	1.0 m/s/s	0.35 m/s/s
EKF2_GYR_NOISE	Rate gyro noise for covariance prediction	0.015 rad/s	0.01 rad/s	0.03 rad/s	0.07 rad/s	0.1 rad/s	0.015 rad/s
EKF2_ACC_B_NOISE	Process noise for IMU accel. bias prediction	0.003 m/s <sup>3</sup>	0.001 m/s <sup>3</sup>	0.003 m/s <sup>3</sup>	0.007 m/s <sup>3</sup>	0.01 m/s <sup>3</sup>	0.003 m/s <sup>3</sup>

### A. GPS and INS local position integration



Fig 2. Mission circuit design

With respect to process noise, the values which can be tuned in the available platform have been systematically analyzed in the six scenarios used, with flights repeating the programmed mission (waypoints), but changing the parameters affecting to EKF performance shown in table IV. The selected values, to analyze the impact on performance metrics appear also in table IV and have been set considered the minimum and maximum values recommended in the implemented EKF2 system.

Fig. 3 presents a zoom of horizontal position estimated by tracking filter and GPS observations (circles), corresponding to right-bottom corner of mission. As can be appreciated, the flights corresponding to higher values of parameters (like flight 1, in blue, flight 5, in black) present lower deviations during turns, and, conversely, are affected more by the sensor noise.

### B. Analysis of innovations

The normalized innovations are presented in this section. Fig. 4 presents aggregated position and velocity in a 6D innovation vector, normalized by its covariance matrix. In this case can be seen that flights 4,5 present the lower values. Table VI summarizes the innovation analysis for the 6 flights. The results showed in detail the system output with different parameters, reflecting the impact assessed through different

magnitudes and the quality metrics considered (averaged innovations and fusion breaks).

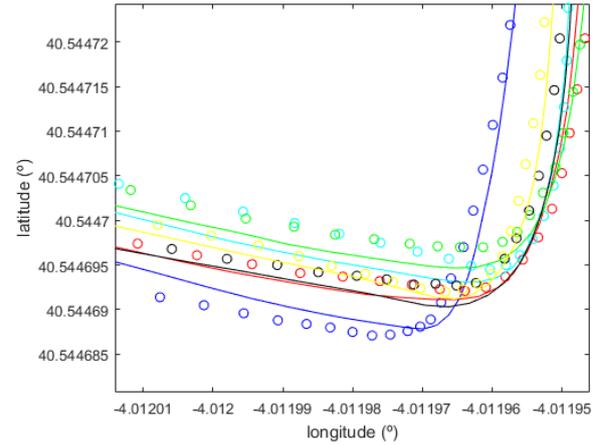


Fig. 3: Details of lat-lon GPS input and EKF output for all flights (1-blue, 2-red, 3-cyan, 4-green, 5-black, 6-yellow)

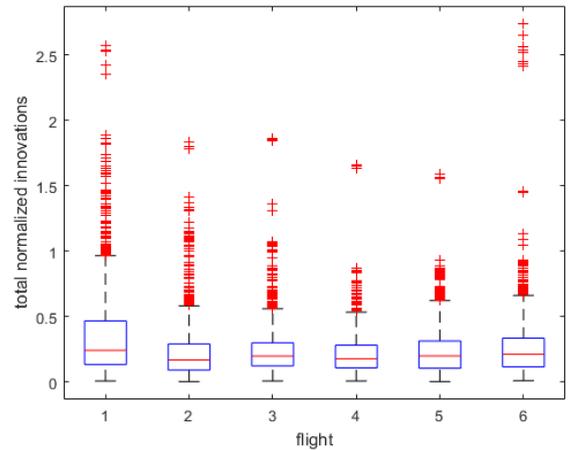


Fig 4. Normalized innovations for all flights

The methodology allows to take decisions of appropriate parameters for the mission considering the global residual of navigation vector and difference with respect to the default configuration, corresponding to the default configuration (flight #4). A moderate improvement in averaged residuals was appreciated, while the robustness in terms of fusion breaks, is

not critically dependent on these parameters within the recommended intervals.

Finally, the methodology can be generalized and applied to different missions and sets of available sensors to explore the sensitivity of fusion algorithms and find the optimal parameters.

## V. CONCLUSIONS

This paper presented a platform (Pixhawk PX4) and methodology to experiment with real data for UAV navigation. Based on data analysis and characterization the algorithms can take advantage of available sources. The quality of all inputs was systematically analyzed, and three processing algorithms, DCM, LPF and EKF, were evaluated with different parameters to exploit the data in the appropriate way considering the output analysis and specific performance metrics not based on ground truth.

So, this work presents a methodology to test and configure UAV navigation systems in real conditions, illustrated with an open environment for experimentation. The analysis of real data in a systematic way will allow successive improvements and parametrization, considering, among others, the following aspects:

- Data filtering to reduce errors and remove outliers
- Quality analysis to weight data uncertainty
- Analysis of biases and calibration previous to fusion.
- Parameter adjustment to optimize performance (PID gains, filter parameters, observation and plant noises, etc.)

## ACKNOWLEDGMENTS

This work was funded by public research projects of Spanish Ministry of Economy and Competitiveness (MINECO), references TEC2017-88048-C2-2-R, RTC-2016-5595-2, RTC-2016-5191-8 and RTC-2016-5059-8.

## REFERENCES

- [1] García J. Molina J.M., J. Trincado. "Analysis of real data with sensors and estimation outputs in configurable UAV platforms". Sensor Data Fusion: trends, solutions and applications 2017. Bonn, Germany, 10-12 Oct. 2017.
- [2] Groves P.D. "Navigation using inertial sensors". IEEE AES Magazine (Vol.30, Iss. 2) 42 - 69 Feb. 2015
- [3] Britting, K.R. "Inertial navigation systems analysis". Artech House, 2010
- [4] Farrel J.A., "Aided Navigation: GPS with High Rate Sensors", McGraw-Hill, New York, 2008.
- [5] Choi H., Kim Y.. "UAV guidance using a monocular-vision sensor for aerial target tracking". Control Engineering Practice, 22, 10-19, 2014.
- [6] Torres-González A., Martínez-de Dios J.R., Ollero A. "Robot-Beacon "Distributed Range-Only SLAM for Resource-Constrained Operation". Sensors 2017, 17(4), 903.
- [7] Ferrick A., Fish J., Venator E. and Lee G.S. "UAV Obstacle Avoidance Using Image Processing Techniques Technologies for Practical Robot Applications (TePRA)", 2012 IEEE International Conference on 23-24 April 2012
- [8] Fasano G., Accado D., Moccia A., Moroney D., "Sense and avoid for unmanned aircraft systems". IEEE Aerospace and Electronic Systems Magazine, vol. 31, n° 11, pp. 82-110, 2016.
- [9] Rankin G., Tirkel A., Leukhin A. "Millimeter Wave Array for UAV Imaging". MIMO Radar Symposium (IRS), 2015 16th International 24-26 June 2015
- [10] Broumandan A., Siddakatte R, Lachapelle G. "An Approach to Detect GNSS Spoofing". IEEE AES Magazine Vol. 32, N8, August 2017. 64-75

TABLE V. RMS OF INNOVATIONS

Variable	Flight 1	Flight 2	Flight 3	Flight 4	Flight 5	Flight 6
Pos_x	0.1456	0.1786	0.2011	0.1958	<b>0.1205</b>	0.1684
Pos_y	0.1366	0.1220	0.1451	0.1368	0.1294	<b>0.1070</b>
Pos_z	0.1674	0.1468	0.1452	<b>0.1414</b>	0.1527	0.1651
Vel_x	0.3495	0.2583	0.2280	<b>0.2059</b>	0.2517	0.2746
Vel_y	0.3250	0.2276	0.2187	<b>0.2025</b>	0.2732	0.2610
Vel_z	0.2115	<b>0.1940</b>	0.2226	0.2192	0.2060	0.2172
Aggregated pos-vel	0.4574	0.3040	0.2878	<b>0.2532</b>	0.2926	0.3456

- [11] Xiao L., "GNSS Receiver Anti-spoofing Techniques: A Review and Future Prospects". 5<sup>th</sup> Electronics and Network conference (CECNet 2015) Shanghai, 2015.
- [12] Carson N., Martin S.M., Starling J., and Bevely D.M. "GPS Spoofing Detection and Mitigation Using Cooperative Adaptive Cruise Control System". 2016 IEEE Intelligent Vehicles Symposium (IV) Gothenburg, Sweden, June 19-22, 2016. 1091-1096
- [13] Blasch E., Pribilski M., Daughtery B., Roscoe B., and Gunsett J., "Fusion Metrics for Dynamic Situation Analysis," Proc. SPIE 5429, April 2004.
- [14] Kim J., Cheng J., Guivant J., Nieto J., "A. Compressed Fusion of GNSS and Inertial Navigation with Simultaneous Localization and Mapping". IEEE AES Magazine Vol. 32, N8, August 2017. 22-36
- [15] Sun R., Cheng Q., Wang G. and Ochieng W.Y. "A Novel Online Data-Driven Algorithm for Detecting UAV Navigation Sensor Faults". Sensors 2017, 17(10), 2243;
- [16] Gao W., Zhang Y. and Wang J." A Strapdown Inertial Navigation System/Beidou/Doppler Velocity Log Integrated Navigation Algorithm Based on a Cubature Kalman Filter". Sensors 2014, 14(1), 1511-1527
- [17] Yao Y. and Xu X. "A RLS-SVM Aided Fusion Methodology for INS during GPS Outages". Sensors 2017, 17(3).
- [18] Jiang C., Zhang S.B. and Zhang Q.Z. "A New Adaptive H-Infinity Filtering Algorithm for the GPS/INS Integrated Navigation". Sensors 2016, 16(12), 2127
- [19] Babister, A. W. (1980). "Aircraft dynamic stability and response" (1st ed.). Oxford: Pergamon Press. ISBN 978-0080247687.
- [20] Hyyti H. and Visala A., "A DCM Based Attitude Estimation Algorithm for Low-Cost MEMS IMUs". International Journal of Navigation and Observation, Volume 2015, Article ID 503814.
- [21] Martí E., García J., Molina J.M. "A Simulation Framework for UAV Sensor Fusion". Hybrid Artificial Intelligence Systems 5th International Conference, HAIS 2010, San Sebastián, Spain, June 23-25, 2010.
- [22] Layh T., Demoz G.E."Design for Graceful Degradation and Recovery from GNSS Interruptions", IEEE AES Magazine Vol. 32, N9, September 2017. 4-17.
- [23] Khaleghi B., Khamis A., Karray F.O., Razavi S.N., "Multisensor data fusion: A review of the state-of-the-art". Information Fusion Volume 14, Issue 1, January 2013, Pages 28–44
- [24] García, J., Luis, Á., Molina, J. M. "Quality-of-service metrics for evaluating sensor fusion systems without ground truth". 19th International Conference on Information Fusion, Heidelberg, Germany, July 2016.
- [25] Colegrove, S. B., Bldg, I. B., Cheung, B., & Davey, S. J. (2003). "Tracking System Performance Assessment". 6th International Conference on Information Fusion, 926–933, Queensland, Australia, July 2003
- [26] Gorji, A.A., Tharmarasa, R., and Kirubarajan, T. "Performance measures for multiple target tracking problems". 14th International Conference on Information Fusion. Chigaco, USA, July 2011.
- [27] Meier L., PX4 Development Guide. [Online]. Available: <https://dev.px4.io/en/>
- [28] Martí E., García J., Escalera A., Molina J.M., Armingol J.M. "Context-Aided Sensor Fusion for Enhanced Urban Navigation". Sensors Vol. 2012 16802-16837. 2012
- [29] Dronecode. PX4 Development Guide [Online]. Available: <https://dev.px4.io/en/simulation/gazebo.html>



# Evasión de obstáculos apoyada en localización basada en simulación de instancias — Navegación autónoma en entornos cerrados.

1<sup>st</sup> Mario Bartolomé Manovel  
*Departamento de Ingeniería Civil*  
*Universidad de Burgos*  
 Burgos, España  
 mario.bartolome@gmail.com

2<sup>nd</sup> César I. García Osorio  
*Departamento de Ingeniería Civil*  
*Universidad de Burgos*  
 Burgos, España  
 cgosorio@ubu.es

3<sup>rd</sup> José-Francisco, Díez-Pastor  
*Departamento de Ingeniería Civil*  
*Universidad de Burgos*  
 Burgos, España  
 jfdpastor@ubu.es

4<sup>th</sup> Alejandro, Merino Gómez  
*Departamento de Ingeniería Electromecánica*  
*Universidad de Burgos*  
 Burgos, España  
 alejandromg@ubu.es

**Resumen**—Este artículo, detalla el uso dado a la implementación de dos algoritmos, con una gran componente estocástica, en la creación de un sistema de navegación en entornos cerrados.

El primero, denominado Filtro de Partículas, e introducido en 1993 por N. Gordon, D. Salmond y A. Smith [5], proporciona un mecanismo de localización basado en filtros bayesianos recursivos, haciendo uso del método de Montecarlo. Se tratará de estimar la posición, realizando múltiples simulaciones del entorno en el que se desplaza el agente.

El segundo algoritmo, denominado *Vector Field Histogram*, Histograma de Campos Vectoriales, o *VFH* por su sigla en inglés, fue introducido por Borenstein y Koren en el año 1991 [2], [3], proporciona un método de evasión de obstáculos basado en el planeamiento, local, de la ruta a seguir por el agente.

Trabajando de forma conjunta, proporcionan un método de evasión de obstáculos y planeamiento de rutas tremendamente robusto.

**Index Terms**—drone, RaspberryPi, filtro de partículas, histograma de campos vectoriales, simulaciones Montecarlo

## I. INTRODUCCIÓN

### I-A. Motivación

Este artículo, es parte de un Trabajo de Final de Grado. La intención tras la implementación, y unión de los métodos a continuación descritos, es que formen parte de un sistema de control automatizado para un *drone*. El Filtro de Partículas fue elegido por su robustez y precisión, frente a sistemas incapaces de funcionar en entornos cerrados. El *VFH* fue elegido como solución a una serie de limitaciones dadas en el uso de algoritmos de Campos Potenciales<sup>1</sup> para la evasión de obstáculos. Lejos de quedarse *sólo* en la teoría, se ha construido un *drone* en el que instalar todo el hardware necesario.

<sup>1</sup>Estos no son adecuados para la navegación en corredores, o entornos altamente ocupados por obstáculos.

### I-B. Estado del arte

Con el creciente uso de sistemas automatizados que ha presentado la industria en los últimos años, el nicho que los *drones* han pasado a ocupar, crece de forma rápida haciendo que se descarten métodos muy consolidados hasta el momento. Vigilancia, industria cinematográfica, ocio, deportes y mensajería son solo algunos de los ejemplos en los que los *drones* se van abriendo camino.

La industria parece moverse hacia sectores dedicados actividades en exterior, donde propuestas como la evasión de obstáculos, pueden ser algo más triviales o innecesarias:

- Sistemas de vigilancia de incendios, campos y cultivos.
- Sistemas de fumigación agrícola.
- Sistemas de inspección de zonas de difícil acceso.
- Sistemas de grabación a nivel profesional.

Sin embargo, parece estar obviándose el uso que se puede dar a un *drone* en un espacio cerrado, ya sea para acceder a zonas complejas en edificios o estructuras con gran cantidad de obstáculos, movimiento de mercancías ligeras en ciudades, en el ámbito militar, o vigilancia en general.

## II. ESTIMACIÓN DE LA POSICIÓN MEDIANTE SIMULACIONES MONTECARLO

El Filtro de Partículas es un algoritmo basado en simulaciones de Montecarlo, y algoritmos bioinspirados. En concreto, se trata de una ramificación de estos. Es un algoritmo de estimación de una distribución, ya que adopta la característica de remuestreo de una población, que presentan los algoritmos genéticos, pero no así otras, como la mutación o cruce.

De esta forma, estimará la posición y orientación de un agente en un entorno, haciendo uso de múltiples hipótesis

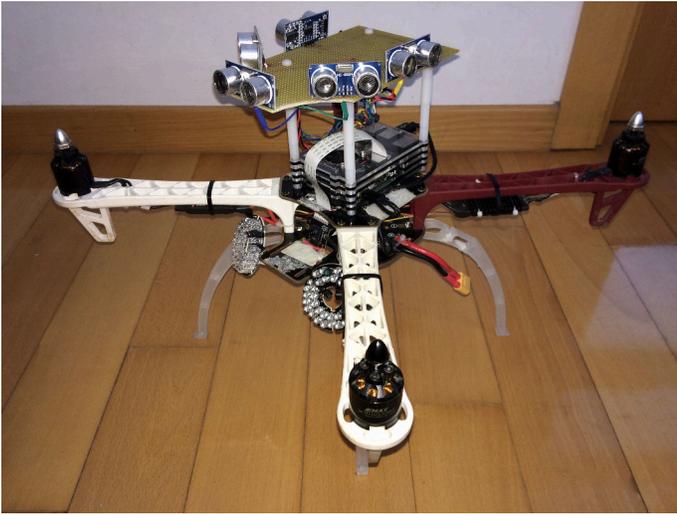


Figura 1. Detalle del *drone* construido, con los sensores de distancia instalados.

ponderadas [6], denominadas partículas<sup>2</sup>. Dicha ponderación, peso o probabilidad, se basa en la similitud de la hipótesis, o partícula, con la instancia que representa el agente.

Para lograr obtener información del entorno, y poder dar una serie de atributos con que poder comparar el agente y las particular que lo simulan, se debe hacer uso de sensores, como los mostrados en la Figura 1, que proporcionen la distancia del agente al obstáculo hacia el que se dirige el sensor.

Habitualmente, se comienza con una distribución de partículas aleatoriamente dispersas por el mapa y con una orientación definida, obviamente no se establecen partículas dentro de obstáculos. Esto, representa el total desconocimiento de la posición del agente, es decir, todas las hipótesis son equiprobables y por lo tanto la posición del agente es, equiprobablemente, cualquier posición del mapa.

A medida que el agente comienza a moverse, las partículas se mueven en la dirección y orientación que determina el agente. A continuación el agente y las partículas toman medidas de su entorno haciendo uso de los sensores de distancia, en el caso del agente, y de forma simulada en el caso de las partículas.

Una vez realizado el movimiento, la distribución de partículas es remuestreada en base a como de parecidas son las hipótesis al estado real del sistema. El remuestreo, o *resample*, conlleva reducir la población de partículas descartando las menos parecidas, o menos probables. De esta manera al cabo de cierto número de iteraciones la distribución converge hacia la posición real del agente.

#### II-A. Representación del estado

El *estado* del agente se puede representar mediante una  $n$ -tupla, donde  $n = 3$  en este caso, tal que:  $[x, y, \theta]$  siendo  $x$  e  $y$  las coordenadas de posición y  $\theta$  la orientación. La altura del agente no es tenida en cuenta, dado que se establece esta

<sup>2</sup>Una *partícula* es el homólogo de un *individuo* en un algoritmo genético.

como fija, es decir, no existen zonas en las que el agente deba navegar a menor o mayor altura para poder acceder, de manera que no es relevante para el cálculo de la posición.

El *peso* de las partículas, o estimación de la probabilidad de que la partícula sea la ubicación real del agente, es una función de densidad de probabilidad distribuida sobre el espacio de estados, descrito en [7]. En el *Filtro de Partículas* la variable de interés, la posición del agente, es representada por un conjunto de  $M$  partículas en el instante  $t = k$ , tal que  $S^k = [e_j^k, w_j^k] : j = 1..M$  tal y como se muestra en [6]. Cada partícula tiene asignado un peso,  $w_j^k$  que define la contribución de esa partícula a la estimación de la posición.

Aquellas regiones del espacio de estados con una gran cantidad de partículas, se corresponden con zonas en las que hay una alta probabilidad de que el agente se encuentre en ellas. Aquellas zonas con una densidad de partículas baja, representan zonas en las que es improbable que el agente se encuentre.

El algoritmo asume la *propiedad de Markov*<sup>3</sup>, de manera que solo funciona correctamente si el entorno es estático.

#### II-B. Actualización de movimiento

Durante la actualización de movimiento, descrita en [1], [6], el agente predice su nueva localización basándose en el movimiento, supuestamente, realizado. Sin embargo, la capacidad del agente de rotar o trasladarse no es perfecta. Si el sistema de evasión de obstáculos indica al agente que debe rotar  $n^\circ$  para dirigirse hacia la meta por un camino seguro, el agente *tratará* de rotar  $n^\circ$ , pero es muy probable que infra/sobrecorrija. Si el agente trata de desplazarse en línea recta, inevitablemente escorará en una dirección u otra.

El movimiento se define de la siguiente manera, para el instante de tiempo  $t = k$ , teniendo en cuenta el *ruido* existente en las medidas de los sensores y sistemas de movimiento:

$$\begin{bmatrix} x' \\ y' \\ \hat{\theta}' \end{bmatrix} = \begin{bmatrix} x + \rho \cdot \cos(\hat{\theta}_k) \\ y + \rho \cdot \sin(\hat{\theta}_k) \\ \hat{\theta}_k + f(rand|\mu, \sigma^2) \end{bmatrix} \quad (1)$$

Donde:

$[x, y, \hat{\theta}]^T$ : Posición inicial del agente.

$\hat{\theta} = \arctan \frac{\delta y}{\delta x}$

$[x', y', \hat{\theta}']^T$ : Posición final del agente.

$\rho = \sqrt{\Delta x^2 + \Delta y^2} \cdot f(rand|\mu, \sigma^2)$ : la distancia a recorrer **añadiendo ruido** dado por una distribución normal.

$\mu = 0,0$ : se desea un valor aleatorio dentro de una gaussiana con centro en 0,0.

$\sigma$ : Errores de los sensores o sistemas de movimiento.

El ruido, como puede verse en la ecuación 1, se genera mediante una función de distribución normal, como la detallada en la ecuación 2, con centro en 0,0 de manera que se pueda simular el hecho de infra/sobrecorregir el movimiento.

<sup>3</sup>En un proceso estocástico que cumple la propiedad de Markov, el estado futuro depende únicamente del estado presente, y no de los estados pasados.



### II-C. Actualización de sensores

Cuando el agente toma medidas a través de sus sensores, actualiza la distribución de partículas de forma ponderada, tal y como se describe en [1], [6], de manera que aquellas que más afinidad presentan en sus mediciones, serán tenidas en cuenta más a menudo que aquellas que no se parezcan al agente.

Para ello, se calcula para cada partícula la probabilidad,  $p_j^k$  de ser la posición real del agente basándose en el estado que esta representa, y haciendo uso de una función de distribución normal, o Gaussiana:

$$p_j^{k+1} = f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2)$$

Donde:

$\mu$  = Distancias de la partícula a los diferentes obstáculos.

$\sigma$  = Ruido del sistema de sensores.

$x$  = Distancias reales obtenidas por los sensores del agente.

Cabe destacar, que la probabilidad  $p_j^{k+1}$  tiene como su períndice  $k + 1$ , determinando este el instante de tiempo siguiente, es decir la probabilidad de la partícula  $j$  **después** de haber realizado el movimiento.

Se le asignará a cada partícula un peso, proporcional a la probabilidad de tratarse de la ubicación del agente:

$$w_j^{k+1} = w_j^k \cdot p_j^{k+1} \quad (3)$$

Dicho peso será normalizado de la forma habitual mediante:

$$w_j^{k+1} = \frac{\tilde{w}_j^k}{\sum_j^M \tilde{w}_j^k} \quad (4)$$

Donde  $\tilde{w}_j^k$  es la medida de peso de una partícula  $j$  en el instante de tiempo  $k$ , antes de ser normalizado.

### II-D. Remuestreo

Una vez que se han obtenido los pesos, el algoritmo deberá generar un nuevo conjunto de partículas a partir del anterior, teniendo en cuenta el peso de cada partícula. Es decir, si se deben generar  $N$  nuevas partículas, el algoritmo deberá escoger de entre el conjunto  $M$  de partículas, dando mayor prioridad a aquellas que tengan mayor peso. Cabe destacar, que el proceso de selección ha de ser con reemplazo, de manera que puede seleccionarse múltiples veces la misma partícula.

De esta forma se genera un nuevo conjunto de partículas  $M_{k+1}$ , en el que la mayor parte de las partículas se encontrará en aquellas posiciones que proporcionen medidas parecidas a las obtenidas por el agente real.

## III. EVASIÓN DE OBSTÁCULOS MEDIANTE PLANEAMIENTO LOCAL DE RUTAS

El *VFH* permite la detección de obstáculos y su evasión mediante el control de la dirección y velocidad del agente en tiempo real.

Para ello realiza una representación del entorno del agente en forma de histograma. Dicho entorno, llamado *Región Activa*

$C^*$ , se representa como una *ventana* que se desplaza con el agente en el centro. Se trata un algoritmo de búsqueda local, sin embargo se ha mostrado que suele producir rutas cercanas al óptimo, aunque en el caso de este proyecto no es relevante, dado que la intención es que se exploren todas las zonas del entorno.

Se compone de tres partes:

1. Red Cartesiana de Histogramas: Derivado del concepto de *malla de certidumbre* propuesto por Moravec y Elfes en 1985, ver [4], en la universidad de Carnegie Mellon. Se construye un plano cartesiano representando el entorno cercano del agente. Por *cercano*, se entiende una distancia que los sensores de distancia puedan abarcar. Dicho plano será representado como un histograma, y de ahí su nombre habitual *Cartesian Histogram Grid*. Ver subsección III-A.
2. Histograma Polar: Una representación unidimensional, obtenida a partir de una reducción de la Red Cartesiana definida en el punto anterior. Se compone de  $n$  sectores angulares  $k$ , de anchura  $\alpha$ , de forma que  $n \cdot \alpha = 360$ ;  $n \in \mathbb{Z}$ . Dichos sectores  $k$  contienen un valor  $h_k$  que representa la densidad de obstáculos, *Polar Obstacle Density* o *POD*, contenida en él. Ver subsección III-B.
3. Capa de salida: Representa el resultado del algoritmo. A partir del POD, se obtienen los posibles *valles*<sup>4</sup> candidatos existentes entre obstáculos, y se elige el que más se aproxime a la dirección de la meta establecida. Así, devolverá la orientación necesaria a seguir por el agente. Ver subsección III-C.

### III-A. Cartesian Histogram Grid

Se modela el espacio cercano al agente en forma de malla. En cada celda  $(i, j)$  de esa malla se encuentra un valor  $c_{i,j} \in \mathbb{Z}$  que establece la certeza de la existencia de un obstáculo. La cantidad de celdas existentes en la malla se establece en función de los límites del sensor, y teniendo en cuenta que es necesario establecer una precisión  $c$ , por ejemplo: Si se dispone de un sensor con un rango de medidas de hasta 400 cm se puede crear una malla de  $81 \times 81$ , suponiendo que cada celda tenga un tamaño de  $c = 5 \text{ cm} \times 5 \text{ cm}$ , en cuyo centro se encuentra el agente, dejando 40 filas y columnas a cada lado. Estableciendo así, un perímetro de medidas de 200 cm en cada dirección, con una precisión de  $\pm 5 \text{ cm}$ .

Dicho valor se obtiene de la lectura proporcionada por el sensor de distancia, y se establece en el centro del ángulo de barrido sensor. La elevada eficiencia de este algoritmo se basa precisamente en incrementar el valor  $c_{i,j}$  de únicamente una celda con cada medida. Dicha celda  $(i, j)$  se encuentra a una distancia de  $R = \frac{\delta_{obsq}}{c}$  celdas y en la bisectriz del ángulo barrido por el sensor. Si bien esta solución puede parecer una simplificación del problema, se llega a generar una distribución probabilística tomando múltiples medidas de forma continua mientras el agente se desplaza por el entorno. Por tanto, la misma celda, cercana a un obstáculo, y sus vecinas serán

<sup>4</sup>Así denominados por su representación en forma de histograma

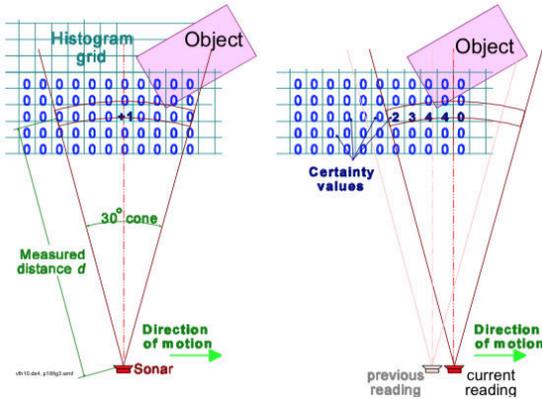


Figura 2. Distribución Histógrámica de Probabilidades. Extraída de [3]

incrementadas repetidas veces, tal y como se muestra en la Figura 2.

### III-B. Polar Histogram

A partir de las medidas obtenidas en el Histogram Grid, se realiza la primera reducción de información para construir un Histograma Polar. Para ello, los contenidos de la región activa  $C^*$  son tratados como un *vector de obstáculos* cuya dirección está definida por la dirección  $\beta$  de la celda en cuestión al centro del agente  $VCP^5$ , y que viene definida por la función:

$$\beta_{i,j} = \tan^{-1} \frac{y_i - y_0}{x_i - x_0} \quad (5)$$

La ecuación 5 devuelve un valor  $\beta \in [-\frac{\pi}{2}, \frac{\pi}{2}]$  rad.

Nótese, que para llevar a cabo la obtención de estos ángulos, se debería utilizar una función que tenga en cuenta el signo de las componentes del vector dirección  $[y_i - y_0, x_i - x_0]$  resultante, de forma que devuelva el ángulo de giro, sea en sentido horario (valores positivos) o antihorario (valores negativos), más corto posible<sup>6</sup>.

La magnitud de cada zona es entonces calculada de la siguiente forma:

$$m_{i,j} = c *_{i,j}^2 \cdot (a - b d_{i,j}) \quad (6)$$

Donde  $a$  representa la fuerza con que un obstáculo afecta al agente, y  $b$  representa la distancia desde la que un obstáculo afecta al agente, ambos positivos.

El plano es convertido en una secuencia de sectores que cubren los  $360^\circ$ . Se definen, por tanto,  $n \in \mathbb{Z}$  sectores  $k$  de amplitud  $\alpha$ , por ejemplo  $n = 72; \alpha = 5$ . Y se distribuyen las medidas tomadas anteriormente en los diferentes ángulos relativos al VCP del agente, en los sectores  $k_i$  correspondientes.

$$k = \frac{\beta_{i,j}}{\alpha} \quad (7)$$

<sup>5</sup>El VCP o *Vehicle Center Point* se define como el centro geométrico del vehículo. En nuestro caso, al tratarse de un *drone*, se considera el centro del mismo como VCP

<sup>6</sup>Obviamente es lo deseable, no sería eficiente realizar un giro de  $225^\circ$  en el sentido de las agujas del reloj, cuando uno de  $135^\circ$  en el sentido contrario a las agujas del reloj bastaría.

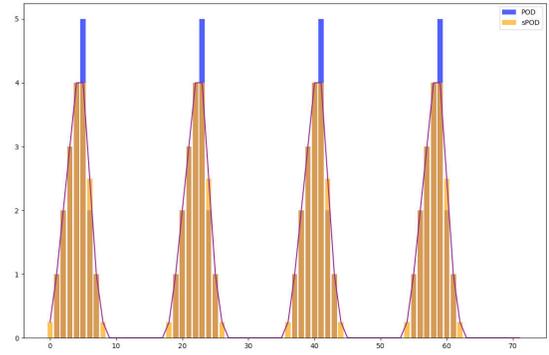


Figura 3. En azul Polar Obstacle Density (POD). En naranja el suavizado de este (sPOD).

con un valor  $h_k$ , véase la ecuación 8, de densidad de obstáculos en ellos:

$$h_k = \sum m_{i,j} \quad (8)$$

Dada la discretización de los datos obtenidos del Polar Histogram el resultado, al realizar esta conversión y al obtener el sumatorio  $h_k$  de todos los valores pertenecientes a un sector  $k$ , puede parecer que el histograma varía de forma muy repentina entre dos sectores. Por ello se aplica una función de suavizado, según J. Borenstein y Y. Koren en [3]:

$$h'_k = \frac{h_{k-l} + 2h_{k-l+1} + \dots + lh_k + \dots + 2h_{k+l-1} + h_{k+l}}{2l + 1} \quad (9)$$

Donde  $l$  es una constante positiva a la que se le ha dado un valor de 5.

Sin embargo, existe una errata en el artículo publicado, y la ecuación 9 no es consistente, i.e: La función de suavizado parece poder expresarse de forma general tal que:

$$h'_k = \frac{1}{2l + 1} \sum_{n=-l}^l (l - |n| + 1) \cdot h_{k+n} \quad (10)$$

ej:  $l = 5$   $h'_k = \frac{1h_{k-5} + 2h_{k-4} + 3h_{k-3} + \dots + 6h_k + \dots + 2h_{k+l-1} + h_{k+l}}{2l+1}$

Como puede verse, el valor central  $6h_k$  correspondiente a  $n = 0$ , no coincide con la posición dada para ese valor de  $n$ , donde el coeficiente que multiplica a  $h_k$  es igual a  $l$  en lugar de  $l + 1$ .

Por ello, se ha hecho uso de la función de suavizado de *Hann*, llamada así por el meteorólogo austriaco Julius van Hann. Se conoce a esta función por el nombre de Campana de Coseno, y se define por la ecuación 11.

$$w(n) = 0,5 - 0,5 \cos \frac{2\pi n}{M-1} \quad 0 \leq n \leq M-1 \quad (11)$$

Donde  $M$  es el número de puntos en la ventana de salida. En este caso tomará el valor de  $l$ .

De esta forma, de obtener un histograma de  $n$  sectores con valores  $h_k$ , posiblemente dispares, en sectores  $k$  contiguos, se pasa a obtener un histograma suavizado, que será de mayor utilidad para el sistema de evasión de obstáculos. Véase la Figura 3.

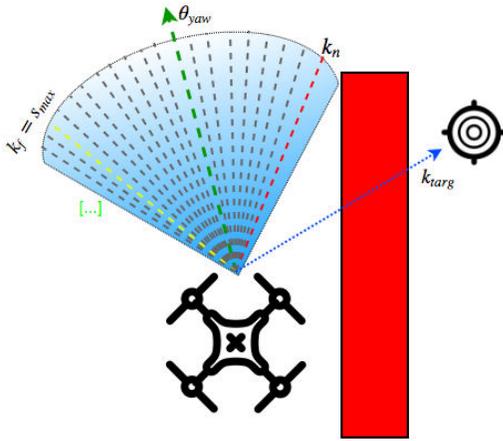


Figura 4. Valle ancho encontrado entre el obstáculo, a la derecha, y un espacio abierto, a la izquierda.

### III-C. Output Layer

En el último estadio del algoritmo VFH, se computa el ángulo de giro  $\theta$  que se debe aplicar al agente para dirigirlo, por una ruta segura, hacia el destino establecido. Una vez obtenido el *Polar Obstacle Density*, y aplicado el suavizado correspondiente, se puede determinar en que sectores  $k$  existe un *valle*. Se define un *valle candidato* como una zona, compuesta de varios sectores por los que es seguro navegar, es decir, están libres de obstáculos o su densidad de obstáculos está por debajo de cierto umbral.

Por lo general, se crean dos o más valles candidatos al analizar el entorno, de forma que es necesario elegir aquel que dirigirá al agente en dirección al destino  $k_{targ}$ . Una vez escogido el valle, se deberá seleccionar el sector  $k$  idóneo. Para ello se mide el tamaño del valle, es decir el número de sectores consecutivos por debajo del umbral que lo componen. De esta forma, se distinguen dos tipos de valles: amplios y estrechos. Los valles amplios son el resultado de espacios grandes entre obstáculos, o de situaciones en las que únicamente existe un obstáculo lo suficientemente cerca del agente. Por *grande* se define una constante  $s_{max}$  que determina el número de sectores  $k$  que componen un valle amplio.

El sector más cercano a  $k_{targ}$  y por debajo del umbral se denomina  $k_n$ , y representa el *borde cercano* del valle. El más lejano se denomina  $k_f$ , y en el caso de los valles amplios, coincide con el valor de  $s_{max} + k_n$ . Véase la Figura 4.

El sector que debe seguir el agente para dirigirse hacia  $k_{targ}$  sin peligro, se denomina  $\theta_{yaw}$ , y su valor es la media de los valores de  $k_n$  y  $k_f$ , como puede verse en la ecuación 12.

$$\theta_{yaw} = \frac{k_n + k_f}{2} \quad (12)$$

Sin embargo, la ecuación 12 presenta un comportamiento errático cuando el destino se encuentra dentro de un valle, dado que se establece  $\theta_{yaw}$  como la media entre los sectores cercano y lejano, al encontrarse la meta en un sector dentro del valle, el agente no se aproxima a ella, sino que realiza

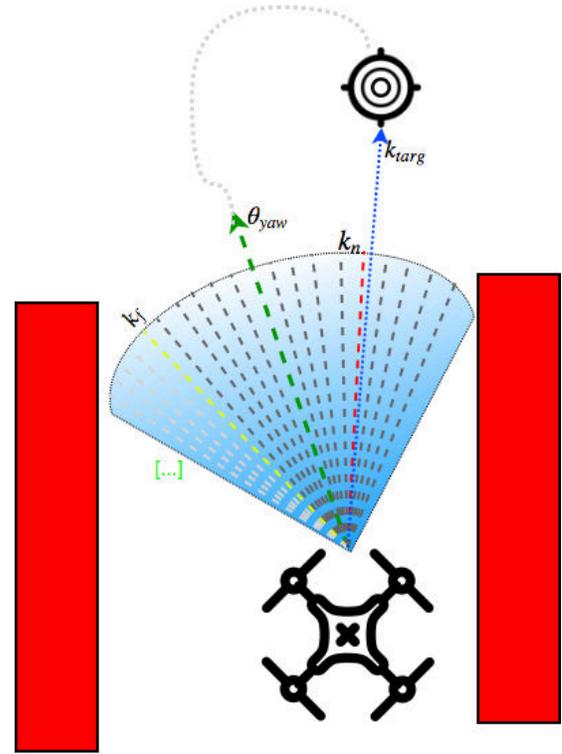


Figura 5. Movimiento circular al encontrarse  $k_{targ}$  en un sector seguro por ecuación 12

círculos cada vez más cerrados hasta llegar al destino, como puede verse en la Figura 5

La intención tras la ecuación 12 es la navegación segura en entornos con obstáculos cercanos, ya que aporta la cualidad de escoger la zona central entre dos obstáculos. Además en el momento en que la posición del agente sea intermedia entre dos obstáculos, la ecuación 12 dará como resultado el mismo sector, con lo que se consigue un movimiento rectilíneo.

Sin embargo, en el momento en el que el destino  $k_{targ}$  se encuentra en un sector  $k$  por el que es seguro navegar, no existe la necesidad escoger la zona intermedia del valle, sino que es deseable dirigirse hacia él directamente.

En el caso de *valles estrechos*, el comportamiento es prácticamente el mismo. Para este caso el valor del último sector con un POD por debajo del umbral escogido será  $k_f < s_{max}$ . Se usa la ecuación 12 para obtener el valor de  $\theta_{yaw}$ , ilustrado en la Figura 6.

El cálculo de la velocidad, se puede derivar en el VFH, haciendo que este calcule la velocidad en base a la ocupación de un sector. Puede calcularse de la siguiente manera:

$$V = V_{max} \cdot \left(1 - \frac{h'_c}{h_m}\right) + V_{min} \quad (13)$$

Dónde:

$$h''_c = \min(h'_c, h_m).$$

$h'_c$  es la POD suavizada en el sector por el que navega el agente.

$h_m$  es una constante establecida de forma empírica.

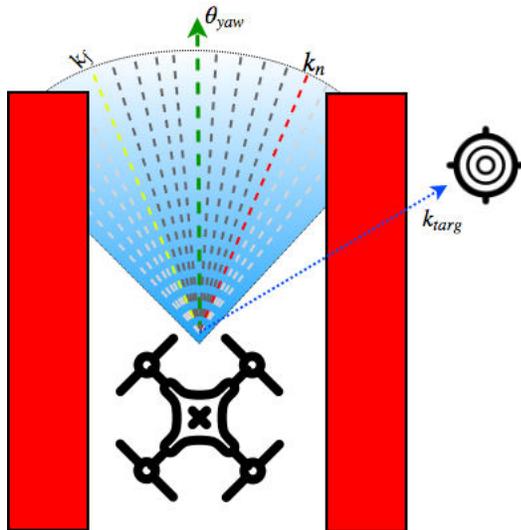


Figura 6. Valle estrecho encontrado entre dos obstáculos. La ecuación 12 proporciona un sector seguro ubicado en la zona central del valle.

$V_{\min}$  es la velocidad mínima del agente.  
 $V_{\max}$  es la velocidad máxima del agente.

*III-C0a. Umbral:* Se ha referenciado numerosas veces el *umbral* que parece definir un valle como candidato. Su definición se ha dejado para el final, debido a que el VFH presenta una gran robustez ante configuraciones probablemente erróneas. Aumentar o reducir el umbral, únicamente, afecta a la anchura de los valles candidatos cuando estos son estrechos. En el caso de los valles anchos sencillamente se aumenta o reduce la distancia existente entre el obstáculo y el agente.

Establecer un umbral muy alto, hace que el agente no sea consciente de la existencia de obstáculos y que se aproxime a ellos. Sin embargo, las repetidas medidas de un obstáculo en ese sector harán que el valor de certidumbre del *Polar Histogram* se eleve hasta superarlo, produciendo que el agente trate de variar su curso. De esta forma el agente se acercará mucho a los obstáculos, haciendo posible que llegue a colisionar, si la velocidad de aproximación es demasiado rápida.

Por el contrario, si el umbral es muy bajo, hará que los valles candidatos se vean reducidos, haciendo que el agente no pueda pasar por espacios estrechos.

#### IV. RESULTADOS PRÁCTICOS

El despliegue de estos algoritmos se ha realizado en una RaspberryPi 3B, haciendo uso de sensores de ultrasonidos HC-SR04, capaces de medir distancias de entre 5 cm y 400 cm con una precisión de  $\pm 1$  cm. Su tasa de adquisición de datos es, aproximadamente, 16Hz para un único sensor. Los sensores deberán obtener sus medidas de forma secuencial, para evitar la recepción de ecos de otros sensores, lo que hace que la tasa se reduzca todavía más, bajando hasta los 3Hz al utilizar 5 sensores. Esto les hace poco fiables para un entorno en producción. I.e., al proporcionar a un controlador PID el valor objetivo, sea la velocidad o la rotación del *drone*, calculado

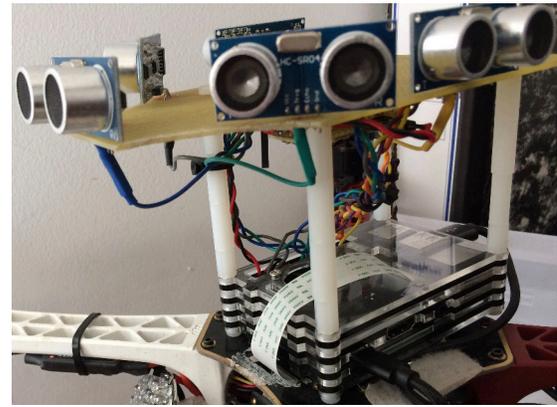


Figura 7. Detalle de los sensores y la RaspberryPi instalada en el *drone*.

por el VFH, tan solo 3 veces por segundo, es **muy** probable que el movimiento se realice con información desactualizada. De hecho, hasta 16Hz se han mostrado insuficientes para llevar a cabo el control de la altitud en un sistema con una dinámica tan alta como es un *drone*.

#### V. CONCLUSIONES Y LÍNEAS FUTURAS

El Filtro de Partículas, pese a ser computacionalmente exigente<sup>7</sup>, provee de un medio para obtener la localización de un agente sin hacer uso de otras tecnologías menos fiables, como GPS, GLONASS o Galileo. Alimentar el VFH con la posición obtenida de un método como el Filtro de Partículas, puede ocasionar movimientos erráticos si se encuentran simetrías en el entorno, haciendo que la población de partículas se disperse en dichas áreas.

Se recomienda encarecidamente hacer uso de sensores con una tasa de adquisición de datos más rápida, como LIDAR o sensores LASER. De la teoría a la práctica hay, sin lugar a dudas, una ingente cantidad de parámetros que ajustar y personalizar en base a la dinámica del sistema elegido.

#### REFERENCIAS

- [1] Domingo Gallardo López. Localización basada en filtros de partículas. *Universidad de Alicante*, 2010.
- [2] Y. Koren J. Borenstein. Real-time obstacle avoidance for fast mobile robots in cluttered environments. *International Conference on Robotics and Automation*, 1990.
- [3] Y. Koren J. Borenstein. The vector field histogram - fast obstacle avoidance for mobile robots. *Transactions on Robotics and Automation*, 7(3), 1991.
- [4] Hans Moravec and A. E. Elfes. High resolution maps from wide angle sonar. In *Proceedings of the 1985 IEEE International Conference on Robotics and Automation*, pages 116 – 121, March 1985.
- [5] Smith N. Gordon, J. Salmond. Novel approach to nonlinear/non-gaussian bayesian state estimation. *IEE Proceedings F (Radar and Signal Processing)*, 140(2), 1993.
- [6] Ioannis M. Rekleitis. A particle filter tutorial for mobile robot localization. *McGill University*, 2003.
- [7] Daniel Sabinasz. Robot localization IV: The particle filter, 2017. [Internet; descargado 9-abril-2018].

<sup>7</sup>Si se dispone el plano como una matriz, en la que en cada posición  $i, j$  se establecen  $n$  partículas para cubrir la mayor cantidad de orientaciones posibles, y cada partícula dispone de  $r$  rayos que intersectan  $o$  obstáculos, dicha matriz no es tal, sino que pasa a ser un tensor tetra-dimensional, o tesseracto.



# Medida de calidad de la planificación de recogida de residuos a partir del conocimiento del experto utilizando aprendizaje de preferencias

Laura Fdez-Díaz      Miriam Fdez-Díaz      José Ramón Quevedo Pérez      Elena Montañés Rocés  
 Global R&D,      Global R&D,      Centro de Inteligencia Artificial      Centro de Inteligencia Artificial  
 ArcelorMittal (España)      ArcelorMittal (España)      Universidad de Oviedo (España)      Universidad de Oviedo (España)

**Resumen**—La investigación incluida en este trabajo surge a raíz de la necesidad de optimizar globalmente el proceso de recogida de residuos de la empresa *Consortio para la Gestión de los Residuos Sólidos de Asturias (COGERSA)*. Hasta ahora, el diseño de la planificación se iba realizando progresivamente bajo demanda, por lo que su optimización no es global. Los expertos crearon la planificación de forma manual construyendo localmente las nuevas rutas de los concejos en cuanto estos solicitaban el servicio de recogida. Un diseño global teniendo en cuenta todas las características de este proceso excede la capacidad de un experto humano debido, principalmente, a la gran cantidad de recursos humanos y materiales disponibles, al alto número de contenedores que se deben recolectar, a las diferentes limitaciones de tiempo y a la dependencia del trazado de la carretera. Normalmente, este tipo de problemas se resuelve utilizando algoritmos de optimización de planificación, para los cuales uno de los requisitos es diseñar una función objetivo que evalúe la calidad de la planificación. En este sentido, el objetivo de este trabajo es diseñar una función objetivo a partir del conocimiento de los expertos que sea capaz de evaluar la calidad de una planificación global de recogida de residuos, como paso previo a una posterior optimización de la planificación. Nuestra propuesta se enmarca dentro del aprendizaje de preferencias, donde además, se propone simplificar las decisiones de los expertos, ya que deberán decidir no entre dos planificaciones completas de la ruta, sino entre dos pares de rutas, que supone una tarea bastante más asequible, incluso abordable. El resultado será una función de ranking de planificación de rutas, donde dada una planificación candidata, se le asignará una puntuación que la coloque dentro del ranking.

**Palabras clave**—Aprendizaje de preferencias, Caracterización de rutas, Función objetivo

## I. INTRODUCCIÓN

Los expertos de la empresa *Consortio para la Gestión de los Residuos Sólidos de Asturias (COGERSA)* planifican rutas de recogida de residuos según la demanda de los ayuntamientos y sin alterar las rutas ya existentes. Con el fin de optimizar en mayor medida los recursos disponibles, la empresa ha decidido realizar una única planificación conjunta. Optimizar los recursos tanto humanos como materiales, el tiempo de recogida o el consumo de combustible, entre otros, no es tarea sencilla ya que hay que tener en cuenta una serie de factores. Por ejemplo, el número de contenedores es fijo y las frecuencias de recogida vienen impuestas por el gobierno, al igual que varias restricciones en la planificación. No se deben recoger contenedores donde no se pueda llevar a cabo

la recogida de residuos, como, por ejemplo, si hay un mercado callejero o en contenedores ubicados en la entrada de colegios o institutos durante el comienzo o finalización del horario escolar. Otro factor a tener en cuenta es el tiempo de trabajo del personal o el uso de los camiones debido a que no se debe sobrepasar un cierto número de horas. También, se tendrá que controlar la distancia que recorre un camión cargado, puesto que para recorrer menos distancia cargado es mejor que el camión recoja los contenedores en el camino de regreso. Además, se debe considerar la lateralidad<sup>1</sup> de los contenedores debido a que en algunas áreas el camión tendrá que dar la vuelta para recoger un contenedor ubicado a la izquierda o derecha de la carretera.

Normalmente este tipo de problema, conocido generalmente como Problema de Enrutamiento de Vehículos (VPR, *Vehicle Routing Problem*) [1], se resuelve utilizando algoritmos de optimización de planificación, los cuales usan una función objetivo para evaluar la calidad de una determinada planificación. Sin embargo, obtener una función objetivo de este calibre teniendo en cuenta todos los factores que involucra no es una tarea trivial, aunque aprendible, como se puede ver en un clásico trabajo en el ámbito del juego de ajedrez [2]. Es por ello por lo que surge esta investigación, la cuál se centra en diseñar una función objetivo que recoja información de los expertos, quedando fuera del alcance de este trabajo la aplicación de esta función en un algoritmo de optimización. La solución que proponemos se enmarca dentro del aprendizaje de preferencias, donde los expertos deben decidir entre pares de planificaciones de rutas cuál es, a su juicio, la mejor planificación dentro de cada par. Sin embargo, esta tarea aún sobrepasa la capacidad humana, incluso la de los expertos, por lo que nuestra propuesta convierte el problema en decidir entre pares de rutas qué miembro de cada par es el mejor, en vez de entre planificaciones de rutas completas. Posteriormente, estas decisiones se utilizarán para diseñar una función objetivo, que, aunque se utilicen decisiones a nivel de ruta, será válida para evaluar planificaciones de ruta. La idea es diseñar una serie de indicadores clave (KPIs) que describan una ruta, teniendo en cuenta, en la medida de lo posible, tanto la información

<sup>1</sup>Lateralidad es la propiedad que tiene un contenedor que indica el lado de la carretera por el que se tiene que recoger.

proporcionada por los expertos como los factores involucrados en todo el proceso de recogida.

Este trabajo se organiza de la siguiente manera. La Sección II describe algunos trabajos relacionados con el tema que nos ocupa. En la Sección III se detalla el proceso de construcción de una función objetivo para evaluar una planificación de recogida de residuos. En la Sección IV se muestran los resultados de los experimentos llevados a cabo, así como la discusión de los mismos. Finalmente, la Sección V esboza algunas conclusiones y propone varias líneas de investigación de trabajo futuro.

## II. TRABAJOS RELACIONADOS

En inteligencia artificial, existen dos formas principales de obtener conocimiento de los expertos. Por un lado, si los expertos pueden describir su conocimiento, este conocimiento puede recogerse en forma de reglas, generando un sistema experto. Por otro lado, y siendo el caso que nos ocupa, si las acciones de los expertos están disponibles pero no son capaces de explicarlas, entonces, es posible utilizar técnicas de aprendizaje automático para extraer su conocimiento.

Existen en la literatura numerosos trabajos cuyas soluciones se obtienen a partir de información de los expertos. Por ejemplo, el trabajo [3] propone un modelo para detectar vertidos de petróleo a partir de información experta. Los expertos debían observar imágenes para detectar regiones sospechosas. En [4] se presenta una estrategia para optimizar la calidad de recuperación de un motor de búsqueda. Un usuario al hacer clic sobre un documento relacionado con una consulta proporciona al motor de búsqueda la información del ranking de los resultados para ese usuario, puesto que el usuario manifiesta que prefiere el documento sobre el que hace clic con respecto al resto de documentos. Esta información alimenta el sistema que genera un modelo capaz de clasificar documentos según las preferencias del usuario. En [5], se genera un modelo que ordena ganado vacuno según su calidad como productores de carne. El ganado se describe mediante medidas de su cuerpo relevantes para los expertos. Las preferencias de los expertos se capturaron y unificaron en una función de ordenación. También, [6] desarrolla una estrategia similar para analizar la información sensorial de un panel de consumidores con el fin de ordenar sus preferencias sobre ciertos productos. De la misma forma, [7] propone un método de aprendizaje automático para obtener los factores más relevantes que afectan a la empleabilidad y el empleo. Para ello, algunos académicos de diferentes campos definieron las competencias que podrían ser importantes para el empleo utilizando los datos de las universidades españolas y cuestionarios de los estudiantes. Los objetivos de este estudio fueron predecir si una persona tendría un empleo o no y extraer los factores más relevantes para conocer la forma más efectiva de preparar a los estudiantes para el mercado laboral. En otro estudio relacionado con la educación [8] se ajusta una rúbrica de una actividad académica a partir de las respuestas de los estudiantes y de las preferencias de los profesores en las respuestas. El objetivo es determinar el peso de cada elemento a partir de rankings parciales generados

por las lecturas de varias respuestas de los estudiantes a la actividad.

## III. CAPTURA DEL CONOCIMIENTO EXPERTO EN LA PLANIFICACIÓN DE LA RECOGIDA DE RESIDUOS

Antes de profundizar en la obtención de una función objetivo que capte el conocimiento experto, hay que mencionar algunos aspectos para comprender mejor el proceso de recogida de residuos que actualmente se está llevando a cabo en la empresa. Los expertos han ido planificando una serie de rutas bajo demanda, optimizadas de forma local para el área demandada en cada momento. Cada ruta comienza y finaliza en el mismo punto, un garaje. Además, cada ruta tiene un grupo de puntos geográficos de recogida que pueden incluir más de un contenedor de la misma capacidad o diferente (si hay más de un contenedor en el mismo punto de recogida, la capacidad de ese punto de recogida es la suma de las capacidades de los contenedores de ese punto). Cada ruta tiene asignado un camión y un equipo humano. Cada equipo humano está formado por recolectores y conductores y ninguno de ellos puede superar las 38 horas de trabajo semanales. Las rutas tienen forma de ramillete porque suelen constar de un área central con una alta frecuencia de recogida (el núcleo del ramillete) y otras con una frecuencia de recogida más baja (las ramas). Esto quiere decir que las rutas, aunque suelen tener la misma periodicidad, cada una tiene sus propios días de ejecución, de forma que los puntos con alta frecuencia de recogida son puntos de intersección de varias rutas y forman el núcleo del ramillete, siendo los puntos de baja frecuencia los que no forman intersección de varias rutas.

Uno de los principales problemas de la planificación actual es que las rutas tienen en general diferente duración, debido básicamente a la forma en que han sido diseñadas, por concejos y bajo demanda (aunque algunas rutas cubren más de un concejo si las áreas son pequeñas). La consecuencia inmediata de ello es que existen diferencias de uso de los camiones y diferencias en las horas de trabajo de los recolectores y conductores. Además, otros factores que dificultan el proceso de recogida son las condiciones climáticas adversas o las posibles demoras en la recogida en empresas privadas por el tiempo empleado en el acceso a los contenedores que tengan en su recinto privado. Otras dificultades son el rango de horas de recogida permitidas, la existencia de vehículos que excedan el peso permitido así como las limitaciones de altura o la dimensión del contenedor en las pequeñas poblaciones. Por otro lado, los trabajadores tienen sus propias preferencias cuando trabajan en pendiente. Por ejemplo, los conductores prefieren subir por una carretera en peores condiciones a cambio de bajar por otra que esté en mejores condiciones y los recolectores prefieren recoger los contenedores cuesta abajo. Otro tema a tener en cuenta es el tiempo de recogida ya que, dependiendo del tipo de camión, éste puede cambiar o el tiempo de descarga en las estaciones de transferencia o el tiempo que tarda el conductor en ir desde el garaje hasta el primer contenedor en la ruta y desde el último contenedor hasta el garaje. También sucede que, por ejemplo, en las



áreas rurales no hay límites de tiempo para la recogida y que en algunos lugares la lateralidad del contenedor no es una característica esencial ya que a veces los contenedores pueden haber sido cambiados. Así mismo, son los gobiernos locales quienes determinan la cantidad de contenedores y la frecuencia de recogida por superficie y población de cada área. Debido a eso, cada contenedor podría tener diferente frecuencia dependiendo del área y podrá variar según la temporada del año (por ejemplo, en verano en las zonas de playa se generan más residuos).

El objetivo de este trabajo es obtener una medida que evalúe la calidad de una planificación teniendo en cuenta, en la medida de lo posible, las restricciones y características del proceso de recogida que se acaba de describir y sirviéndose también del conocimiento de los expertos, para lo cual, nuestra propuesta consiste en utilizar aprendizaje de preferencias. En este marco, el proceso ideal sería disponer de varios pares de planificaciones de recogida de residuos sobre los cuales los expertos indicasen qué miembro de cada par sería, a su juicio, el mejor. Sin embargo, debido a la alta complejidad que presenta la planificación, ni siquiera los expertos serían capaces de decidirse entre los miembros de cada par de planificaciones. Por esta razón, se propone simplificar el problema al nivel de ruta, en lugar de considerar planificaciones completas. Por tanto, se establecerán KPIs que evalúen la calidad de una ruta en vez de la calidad de una planificación, aunque se verá más adelante que también permitirán evaluar una planificación. La descripción y el diseño de estos KPIs se detalla en la sección III-A. Una dificultad acaecida de este planteamiento es la necesidad de disponer de un número suficiente de pares de rutas sobre los cuales los expertos puedan decantarse por un miembro de cada par. Sin embargo, las únicas rutas disponibles son precisamente las que forman la planificación actual, que no son suficientes y, por tanto, surge la necesidad de crear rutas alternativas. Esta tarea se explica en la sección III-B.

#### A. Diseño de evaluación de indicadores de calidad (KPIs) para una ruta de recogida

En esta sección se proponen varios KPIs que permiten evaluar la calidad de una ruta recogiendo, en la medida de lo posible, los factores más relevantes para los expertos en recogida cuando estos diseñan una ruta. La mayoría de los KPIs por los que los expertos se inclinan están relacionados con las propiedades geográficas y se detallan y discuten a continuación.

1) *Distancia recorrida*: Uno de los KPIs más básicos que proponen los expertos es la distancia recorrida. Para obtener su valor, se considera  $\{p_1, p_2, \dots, p_n\}$  un conjunto de puntos de recogida de una ruta cuyo garaje inicial y final sea  $g$  y se obtiene a partir de otras distancias ( $D$ ) más pequeñas en el mapa, a saber:

- i) Distancia desde el garaje  $g$  al primer punto de recogida  $p_1$ ,  $D(g, p_1)$ , y desde el último punto de recogida  $p_n$  al garaje  $g$ ,  $D(p_n, g)$ .
- ii) Distancia entre puntos de recogida calculada como la suma de cada distancia entre el punto de recogida actual

$p_i$  y el siguiente punto de recogida  $p_{i+1}$ , es decir,  $D(p_1, p_n) = \sum_{i=1}^{n-1} D(p_i, p_{i+1})$

Por lo tanto, la distancia total de viaje de una ruta es la suma de dichas distancias.

$$D(g, g) = D(g, p_1) + D(p_1, p_n) + D(p_n, g) \quad (1)$$

2) *Tiempo empleado*: El tiempo empleado es uno de los KPIs más importantes que tenemos que tener en cuenta, debido al tiempo máximo de trabajo de los trabajadores y de uso de los camiones, así como a las restricciones existentes en los horarios de recogida. Debido a que solamente se dispone del tiempo empleado en las rutas diseñadas localmente por los expertos, la obtención de dicho KPI es más compleja de lo que parece, de hecho, no es posible calcularlo con la información facilitada. Por lo tanto, a partir de la información local disponible, se propone obtener un modelo de regresión que sea capaz de estimar este tiempo. En esta línea, y para facilitar el proceso de aprendizaje, se propone dividir el tiempo en dos partes:

- i) Tiempo transcurrido desde el garaje  $g$  al primer punto de recogida  $p_1$  y desde el último punto de recogida  $p_n$  al garaje  $g$ . El sistema de regresión se alimenta con la distancia y el tiempo de cada uno de estos trayectos. El resultado es una función de regresión  $T_g$  que estima el tiempo transcurrido en los tramos de la ruta que involucran el garaje.
- ii) Tiempo transcurrido entre los puntos de recogida (distancia entre el primer punto  $p_1$  y el último punto  $p_n$ ). En este caso se usa el número de puntos de recogida y el tiempo para alimentar el sistema de regresión y así obtener otra función de regresión  $T_p$ .

Una vez que están disponibles las dos funciones de regresión  $T_g$  y  $T_p$ , el tiempo de predicción utilizado en una determinada ruta será la suma de tres partes: i) del garaje  $g$  hasta el primer punto de recogida  $p_1$  que utiliza  $T_g$ , ii) del primer punto de recogida  $p_1$  hasta el último punto de recogida  $p_n$  usando  $T_p$  y finalmente iii) del último punto de recogida  $p_n$  al garaje  $g$  utilizando  $T_g$  nuevamente. Por lo tanto, el tiempo total del trayecto de una ruta es la suma de los tiempos anteriores:

$$T(g, g) = T_g(g, p_1) + T_p(p_1, p_n) + T_g(p_n, g) \quad (2)$$

Una casuística que puede darse es que el tiempo predicho sea menor que el real, en cuyo caso se superaría el tiempo de turno de trabajo. Para poder evitar este comportamiento, se propone aplicar un factor de corrección, el cuál solo podrá calcularse a partir de las rutas disponibles, que son las rutas de la planificación actual diseñadas localmente por el experto. Con este propósito, se evalúa la diferencia entre los valores reales y predichos y se supone que la muestra resultante debe seguir una distribución normal. El valor de corrección será el valor para el cual la diferencia es positiva a cierto nivel significativo. Por contra, si el tiempo predicho es mayor, no presenta ningún problema, ya que el tiempo de turno de trabajo se respetaría.

3) *Altitud acumulada*: Otro factor que los expertos consideran relevante es el relieve del terreno. Esto es así porque, por ejemplo, un terreno escarpado complica el acceso de los camiones a los contenedores. Además, no es igual de costoso que un camión vaya cuesta arriba con una mayor carga que vaya cuesta abajo, no solo por mantener el buen estado de los camiones, sino por el consumo de combustible. Por ello, el KPI que se propone para considerar el relieve del terreno es la altitud acumulada. Se puede pensar en utilizar el porcentaje de pendiente como un KPI, sin embargo, los expertos descartaron esta opción debido a que no contempla la distinción entre subir un tramo largo con pendiente más baja o subir un tramo corto con pendiente más alta.

A partir de un conjunto de puntos de la ruta <sup>2</sup>,  $t_1, \dots, t_m$  se obtienen sus respectivas altitudes  $A(t_1), \dots, A(t_m)$ . El KPI de altitud acumulada para una ruta que comienza en un garaje  $g$  y termina en el mismo garaje se evalúa de la siguiente manera.

$$A(g, g) = \sum_{i=1}^{m-1} \max(0; A(t_{i+1}) - A(t_i)) \quad (3)$$

Este KPI solo contempla la diferencia de altura en los tramos de subida, pues al tratarse de rutas circulares, la diferencia de altura en los tramos de bajada es idéntico al correspondiente a los tramos de subida.

4) *Tipo de carretera*: El tipo de carretera es también un KPI relevante para los expertos, ya que conducir por una autopista difiere considerablemente con respecto a conducir por carreteras locales. Por ejemplo, el consumo de combustible, la comodidad o el tiempo que dura el trayecto son aspectos que cambian según el tipo de la carretera. Los tipos de carreteras se clasifican según su relevancia (de mayor a menor) como autopista, autovía, carreteras regionales, carreteras locales y otras (avenida, calle, camino, plaza...).

Para tener en cuenta estos tipos de carretera, se consideran dos KPIs adicionales, a nombrar, la distancia por carreteras menos importantes ( $D_b$ ), que incluye plazas, calles, caminos, avenidas y carreteras locales, entre otros y la distancia por carreteras menos importantes y de importancia intermedia ( $D_i$ ), que incluye, además de las anteriores, carreteras regionales. Por lo tanto,  $D_b(g, g)$  y  $D_i(g, g)$  se calculan para una ruta.

5) *Carga del camión*: La carga del camión es otro aspecto por el cual los expertos mostraron gran interés ya que probaron estadísticamente que conducir muchos kilómetros con una carga pesada afecta en gran medida al consumo de combustible y al desgaste del camión. Por ello, si la recogida de residuos se realiza en el trayecto de ida y luego se regresa al garaje se estaría cargando con la carga durante todo el trayecto de vuelta. Por este motivo, parece preferible ir en primer lugar al punto de recogida más alejado de la ruta sin carga en el camión y regresar recogiendo los residuos.

No es fácil indicar de forma directa en un KPI la carga del camión, ya que el consumo de combustible o el desgaste del camión son prácticamente imposibles de estimar. Por esta

<sup>2</sup>Estos puntos incluyen los puntos de recogida y otros puntos del recorrido del camión para conseguir una mejor estimación de la altitud.

TABLE I  
RESUMEN DE KPIs CONSIDERADOS PARA EVALUAR UNA RUTA

Tramo/KPI	Distancia	Tiempo	Altitud	Distancia carr. poco importantes	Distancia carr. poco imp. + imp intermedia	Carga
Primer tramo.	$D(g, p_1)$	$T_g(g, p_1)$	$A(g, p_1)$	$D_b(g, p_1)$	$D_i(g, p_1)$	-
Segundo tramo.	$D(p_1, p_n)$	$T_p(p_1, p_n)$	$A(p_1, p_n)$	$D_b(p_1, p_n)$	$D_i(p_1, p_n)$	-
Tercer tramo.	$D(p_n, g)$	$T_g(p_n, g)$	$A(p_n, g)$	$D_b(p_n, g)$	$D_i(p_n, g)$	-
Ruta completa.	$D(g, g)$	$T(g, g)$	$A(g, g)$	$D_b(g, g)$	$D_i(g, g)$	$C(g, g)$

razón, este factor se tendrá en cuenta no a través de la propia carga del camión, sino con una medida relacionada con el consumo de combustible (ni siquiera el propio consumo de combustible). Nuestra propuesta para considerar este factor  $C$  consiste en suponer que el punto de recogida actual es el último punto de recogida de la ruta. Por lo tanto, si  $D_g$  es la distancia desde el punto de recogida actual  $p_i$  hasta el garaje final  $g$  y  $L$  es la carga del camión de los residuos recogidos desde el garaje origen  $g$  hasta el punto de recogida actual  $p_i$ , el KPI para el punto de recogida actual  $p_i$  será el producto de la carga de residuos y la distancia restante que lleva la carga hasta el final de la ruta, es decir,  $C(p_i) = L(p_i) \cdot D_g(p_i)$ . La principal dificultad llegado este punto es que no se dispone ni del volumen ni del peso de los residuos que se recogen, por lo que podría parecer que la solución más directa consistiría en estimarlo. Sin embargo, los expertos descartaron esta opción, ya que argumentaron que el ruido que puede conllevar la estimación no compensaría la posible mejora del KPI. En consecuencia, el experto recomendó establecer  $L(p_i) = 1$  para todos los puntos de recogida, dando lugar a una versión más simplificada del KPI,  $C(p_i) = D_g(p_i)$ . Finalmente, la carga del camión de toda la ruta se considera a través de la media de todos los puntos de recogida.

$$C(g, g) = \frac{\sum_{i=1}^n C(p_i)}{n} \quad (4)$$

El numerador está relacionado proporcionalmente con el consumo de combustible. Sin embargo, debido a que en general las rutas tienen un número diferente de puntos de recogida, se propone promediar precisamente por el número de puntos de recogida con el fin de hacer las rutas comparables.

*Consideraciones finales*: Dada la existencia de tres tramos claramente diferentes en cada ruta (garaje-primer punto de recogida, primer-último punto de recogida y último punto de recogida-garaje), se obtuvieron los KPIs tanto para la ruta completa (21 KPIs) como para cada uno de los tres tramos (el KPI relativo a la carga del camión únicamente se obtiene para la ruta completa). La Tabla I muestra un resumen de los KPIs que se han obtenido. Finalmente, mencionar que los KPIs diseñados, no solo permiten describir una ruta, si no también una planificación.

#### B. Creación de pares de preferencias

Como se mencionó anteriormente, solamente se dispone de rutas diseñadas de forma local de un determinado área. Sin embargo, con el fin de poder aplicar un algoritmo de aprendizaje de preferencias, es necesario construir rutas alternativas



que sirvan de comparación con las existentes. En esta línea, para cada ruta existente, se obtienen otras rutas con pequeñas variaciones aleatorias y se calculan los KPIs para todas ellas, tanto para la existente como para las obtenidas a partir de ella. Si los valores de todos los KPIs de la ruta original son mejores que los de una de las rutas obtenidas a partir de ella, entonces se tomará automáticamente como mejor ruta la ruta original. En caso contrario, se tomará como mejor ruta la obtenida a partir de ella. Por tanto, los pares de rutas (para cada ruta, se generó una única ruta con variaciones aleatorias) se dividen en tres conjuntos:

- i) Los pares de rutas donde todos los KPIs de la ruta existente son mejores que los de la ruta obtenida a partir de ella.
- ii) Los pares de rutas donde todos los KPIs de la ruta existente son peores que los de la ruta obtenida a partir de ella.
- iii) Los pares de rutas con algunos KPIs mejores en la ruta existente y el resto de KPIs mejores para la ruta obtenida a partir de ella.

De las 64 rutas ya existentes, solo hubo un par de rutas que cumplió la condición i) y otro par que cumplió la condición ii), siendo los 62 pares restantes del grupo de pares de rutas los que cumplen la condición iii). La decisión para los pares de rutas del grupo i) y ii) es obvia. Sin embargo, los pares de rutas que cumplen iii) se mostraron al experto para que manifestase sus preferencias.

Una vez que están disponibles los pares de rutas y establecida la preferencia por parte del experto, se lleva a cabo el proceso de aprendizaje. A este respecto, se prefiere una ruta con KPIs  $x$  a una ruta con KPIs  $y$  si la función de evaluación es mayor para  $x$  que para  $y$ .

$$x \succ y \Rightarrow f(x) > f(y) \Rightarrow f(x) - f(y) > 0 \quad (5)$$

En nuestro caso, se necesitaría que  $f$  sea lineal, es decir, que se cumpla que  $f(x) - f(y) = f(x - y)$ . Y por lo tanto:

$$x \succ y \Rightarrow f(x - y) > 0 \quad (6)$$

En nuestro caso, la función  $f$  sería la función objetivo que pondere los KPIs y sirva para evaluar una ruta, que como se comentó anteriormente, dado el diseño que se ha hecho de los KPIs, también servirá para evaluar una planificación. Cada par de rutas se transforma en un par de ejemplos que alimentará el sistema que genere dicha función. Los atributos  $x_i$  e  $y_i$  serían el  $i$ -ésimo KPI para las rutas  $x$  e  $y$  respectivamente y las clases serían +1 y -1, dependiendo de si se prefiere la primera ruta del par o la segunda. Si  $x \succ y$ , el par de ejemplos generados serían  $(x_1 - y_1) \dots (x_n - y_n) \rightarrow +1$  (positivo) y  $(y_1 - x_1) \dots (y_n - x_n) \rightarrow -1$  (negativo). A partir de este conjunto de ejemplos, se generará un modelo de clasificación lineal, que permitirá inducir la función objetivo  $f$ . Particularmente, el valor numérico obtenido por el modelo lineal aplicado a una ruta o planificación nos proporcionará la posición en el ranking de dicha ruta o planificación.

## IV. EXPERIMENTOS

En esta sección se describen los experimentos realizados para obtener sendos modelos i) de regresión que estime el tiempo empleado en una ruta y ii) de ranking para evaluar la calidad de la ruta. Sin embargo, previamente, se discute sobre los sistemas de información geográfica empleados para el cálculo de los KPIs.

### A. Sistemas de información geográfica para obtener los KPIs

Los KPIs se calcularon mediante un sistema de información geográfica (GIS) llamado *Open Source Routing Machine* (OSRM) (<https://map.project-osrm.org/>) y basado en *OpenStreetMap* ([www.openstreetmap.org](http://www.openstreetmap.org)). Hay una variedad de proyectos que han utilizado OSRM<sup>3</sup> y OSM<sup>4</sup>.

A pesar de que OSRM no incluye datos de altitud y ofrece información bastante incompleta en algunas áreas de baja densidad de población porque son los usuarios los que incorporan los datos, es una buena opción ya que además de no tener coste alguno, su documentación y su comunidad es muy extensa.

Otras alternativas a OSRM son *Google Maps* (<https://www.google.com/maps>) que incorpora datos de elevación e información geográfica muy completa, *Mapbox* (<https://www.mapbox.com/>) que está equipado con un módulo de enrutamiento orientado al tráfico, *GraphHopper* (<https://www.graphhopper.com/>) que dispone de una API de optimización de rutas y también de datos de elevación, *Mapzen Valhalla* (<https://mapzen.com/>) que además de permitir diferentes tipos de vehículos, también calcula la forma más eficiente de visitar múltiples destinos y tiene datos de elevación. Sin embargo, todos presentan la desventaja de no ser libres para una elevada cantidad de solicitudes a sus servidores.

Por otro lado, para paliar la carencia de OSRM de proporcionar datos de altitud, proponemos utilizar el modelo de elevación global denominado GMTED2010 (<https://lta.cr.usgs.gov/GMTED2010>), debido a que el número de solicitudes no está limitado. Este sistema fue desarrollado por el Servicio Geológico de los EE. UU. (USGS) y la Agencia Nacional de Inteligencia Geoespacial (NGA). Así, OSRM proporciona un conjunto de puntos de un tramo que alimentan al sistema GMTED2010 para obtener la altitud de los mismos.

### B. Regresión

Los modelos  $T_q$  y  $T_p$  se crearon utilizando la librería Caret4 (*classification and regression training*) en R. Se compararon los métodos *Linear Regression* (LiR), *Bagged CART* (BC), *Bayesian Generalized* (BG), *Boosted Tree* (BT), *Random Forest* (RF) y *Bayesian Ridge Regression* (BRR). Los valores de los parámetros fueron  $maxdepth=2$  y  $mstop=50$  para BT y  $mtry=1$  para RF. La Tabla II muestra el error cuadrático medio (RMSE, *Root Mean Square Error*) y su desviación estándar (RMSE SD) obtenidos en validación cruzada con 10

<sup>3</sup> *I Bike Cph* (<https://www.ibikecph.dk/en>), *Cycle.Travel* (<http://cycle.travel/>) y *MAPS.ME* (<https://maps.me/>)

<sup>4</sup> *Waymarked Trails* (<http://www.waymarkedtrails.org/>), *Open Topo Map* (<https://opentopomap.org/>), *MTBmap* (<https://openmtbmap.org/es/>) o *Thunderforest* (<http://www.thunderforest.com/>)

TABLE II  
 RMSE Y RMSE SD PARA LOS MODELOS DE REGRESIÓN  $T_g$  Y  $T_p$ 

Algoritmo	Modelo $T_g$		Modelo $T_p$	
	RMSE	RMSE SD	RMSE	RMSE SD
LiR	489,65	82,18	525,72	163,41
BC	530,91	83,69	693,10	285,93
BG	489,65	82,18	525,72	163,41
BT	498,67	75,34	665,98	273,68
RF	542,87	78,55	521,35	156,71
BRR	<b>489,50</b>	83,00	<b>520,70</b>	167,14

 TABLE III  
 C-INDEX DE LOS ATRIBUTOS

Algoritmo	5KPIs	6KPIs	15KPIs	16KPIs	21KPIs
SVM	0,4857	0,7429	0,7714	0,8000	0,7714
LoR	0,7714	<b>0,8857</b>	0,7714	0,8000	0,8000

*folds* y 3 repeticiones, siendo BRR el método que mejores resultados ofrece para ambos modelos  $T_g$  y  $T_p$ .

### C. Preferencias

En el aprendizaje de preferencias se utilizó regresión logística (LoR, *Logistic Regression*) y máquinas de vectores soporte (SVM, *Support Vector Machines*) [9] con *kernel lineal*. Se trata de sendos sistemas de clasificación que proporcionan una puntuación que sirve como valor de ordenación y que han sido aplicados con anterioridad en otros ámbitos [5], [6] o [8]. En el ámbito que nos ocupa, se varió el número de atributos (KPIs): 5 KPIs (KPIs de la ruta completa sin la carga del camión), 6 KPIs (KPIs de la ruta completa), 15 KPIs (5 KPIs por cada uno de los tres tramos), 16 KPIs (KPIs por tramos junto con la carga del camión) y 21 KPIs (todos los KPIs, los 5 KPIs de cada tramo junto con los 6 KPIs de la ruta completa).

Como medida de evaluación del modelo se utilizó el C-index, que se estimó mediante validación cruzada por bloques. Cada bloque está formado por una ruta y su variante modificada aleatoriamente. Para cada bloque se calculó el C-Index y finalmente se promediaron los C-Index de todos los bloques. C-index es la probabilidad de concordancia entre los valores predichos y los valores reales, es decir,  $C\text{-Index} = \frac{1}{|\epsilon|} \sum_{\epsilon_{ij}} 1_{f(x_i) < f(x_j)}$ .

La tabla III muestra el C-Index de todas las variantes, siendo LoR mejor o igual que SVM. El mejor resultado se obtiene cuando se considera la carga del camión, resultado, en cierta medida, esperable, ya que los expertos auguraban la relevancia de este factor. Sin embargo, la separación en tramos con recogida de contenedores y tramos de salida y llegada al garaje no resulta adecuada, puesto que el mejor resultado se obtiene cuando no se realiza dicha separación. Es, por tanto, el uso de 6 KPIs la elección preferible.

### V. CONCLUSIONES Y TRABAJO FUTURO

En este artículo se propone una medida que evalúe la calidad de una ruta o planificación de recogida de residuos de la empresa COGERSA. Para ello se ha tenido en cuenta, en la medida de lo posible, las restricciones y características del

proceso que los expertos nos han proporcionado. Se diseñó una serie de KPIs que describen las rutas y se aplicó un sistema de aprendizaje de preferencias para obtener una función objetivo que capturase el conocimiento de los expertos. Para ello, fue necesario crear rutas con pequeñas variaciones aleatorias para que los expertos pudiesen decidir qué ruta preferían (su ruta o la variada aleatoriamente). También fue necesario inducir dos modelos de regresión para poder estimar uno de los principales KPIs de gran interés para los expertos, el tiempo de recorrido de una ruta. Las rutas fueron divididas en tres tramos claramente diferenciados (garaje a primer punto de recogida, primer a último punto de recogida y último punto de recogida a garaje) y los KPIs también fueron obtenidos para dichos tramos. Sin embargo, la mejor función objetivo se obtuvo cuando se consideran exclusivamente los KPIs de la ruta completa. Además se puede concluir que la carga del camión es uno de los factores relevantes en la recogida, algo que los expertos ya intuían. Como trabajo futuro se podrían incorporar nuevos KPIs utilizando un sistema de red vial o establecer cambios en las rutas si las carreteras estuvieran cerca de áreas con problemas de tráfico.

### AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por el Ministerio de Economía y Competitividad español a través del proyecto TIN2015-65069 y por el Instituto de Desarrollo Económico del Principado de Asturias (IDEPA) a través del proyecto RDI *Smart Waste Collection* (SWC), desarrollado por el consorcio COGERSA, SADIM S.A., S.M.E-grupo HUNOSA y ABAMobile (IDE/2015/000863, IDE/2015/000864 e IDE/2015/000865).

### REFERENCIAS

- [1] P. Toth and D. Vigo, "The vehicle routing problem, ser. *siam monographs on discrete mathematics and applications*," *Society for Industrial and Applied Mathematics*, 2002.
- [2] A. L. Samuel, "Some studies in machine learning using the game of checkers," *IBM Journal of Research and Development*, vol. 3, no. 3, pp. 210–229, July 1959.
- [3] M. Kubat, R. C. Holte, and S. Matwin, "Machine learning for the detection of oil spills in satellite radar images," *Machine learning*, vol. 30, no. 2-3, pp. 195–215, 1998.
- [4] T. Joachims, "Optimizing search engines using clickthrough data," in *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining*. ACM, 2002, pp. 133–142.
- [5] A. Bahamonde, G. F. Bayón, J. Díez, J. R. Quevedo, O. Luaces, J. J. Del Coz, J. Alonso, and F. Goyache, "Feature subset selection for learning preferences: a case study," in *Proceedings of the twenty-first international conference on Machine learning*. ACM, 2004, p. 7.
- [6] A. Bahamonde, J. Díez, J. R. Quevedo, O. Luaces, and J. J. del Coz, "How to learn consumer preferences from the analysis of sensory data by means of support vector machines (svm)," *Trends in food science & technology*, vol. 18, no. 1, pp. 20–28, 2007.
- [7] F. J. García-Peñalvo, J. Cruz-Benito, M. Martín-González, A. Vázquez-Ingelmo, J. C. Sánchez-Prieto, and R. Therón, "Proposing a machine learning approach to analyze and predict employment and its factors," *International Journal of Interactive Multimedia and Artificial Intelligence*, no. In Press, 2018.
- [8] J. Quevedo and E. Montañés, "Obtaining rubric weights for assessments by more than one lecturer using a pairwise learning model," *International Working Group on Educational Data Mining*, 2009.
- [9] D. Fradkin and I. Muchnik, "Support vector machines for classification," *DIMACS Series in Discrete Mathematics and Theoretical Computer Science*, vol. 70, pp. 13–20, 2006.



# Data science for building energy management: A review

M. Molina-Solana\*, M. Ros<sup>†</sup>, M.D. Ruiz<sup>†</sup>, J. Gómez-Romero<sup>†</sup> and M.J. Martin-Bautista<sup>†</sup>

\*Data Science Institute, Imperial College London, United Kingdom

Email: m.molina-solana@imperial.ac.uk

<sup>†</sup>Department of Computer Science and Artificial Intelligence, Universidad de Granada, Spain

Email: marosiz@ugr.es, mdruiz@decsai.ugr.es, jgomez@decsai.ugr.es, mbautis@decsai.ugr.es

Summary of published paper: M. Molina-Solana, M. Ros, M. Dolores Ruiz, J. Gómez-Romero, M.J. Martin-Bautista, *Data science for building energy management: A review*, **Renewable and Sustainable Energy Reviews**, Volume 70, 2017, Pages 598-609, ISSN 1364-0321, doi: 10.1016/j.rser.2016.11.132. IF: 9.184. ([original source](#))

**Abstract**—The energy consumption of residential and commercial buildings has risen steadily in recent years, with expected energy loads, transportation, storage and user behaviour influencing the quantity and quality of the energy consumed daily in buildings. Technology is now available that can accurately monitor, collect, and store the huge amount of data involved in this process, as well as analyzing and exploiting such data in meaningful ways. Our paper [1] reviewed how Data Science has been applied to address the most difficult problems faced by practitioners in the field of Building Energy Management. It also discussed the challenges and opportunities that will arise with the advent of fully connected devices and new data processing technologies.

## I. INTRODUCTION

Residential and commercial buildings are currently responsible for up to 40% of the energy consumption in the world [2]. Increasing energy efficiency is a two-fold process. Not only does it involve the use of affordable energy sources, but also the improvement of current energy management procedures and infrastructures. The latter includes the optimization of energy generation and transportation based on user demand [3]. In this regard, computer-aided approaches have recently come into the spotlight. In the area of building energy management, Data Science is now used to address problems in different areas, ranging from energy demand prediction to operation optimization and energy fraud detection.

Our paper [1] analyzes the application of Data Science methods to these problems. Although there are other reviews on automatic techniques for building efficiency assessment [4], [5] and classification methods for load and energy consumption prediction [6], this work examined and discussed a broader set of data science techniques and their applications to the different aspects of building energy management. We present here a brief summary of the most relevant techniques identified by our study, some reflections on the possible evolution of the area in the near future and the main conclusions of the work.

## II. APPLICATIONS OF DATA SCIENCE FOR BUILDING ENERGY MANAGEMENT

**Prediction of building energy load.** Energy demand, or energy load, refers to the amount of energy required at a certain time period. Detecting building load patterns can be complex because of the number of interrelated factors. In the literature, we can find different proposals for customer profiling using unsupervised learning, e.g. clustering and association rules, and classification models, such as decision trees. For peak demand anticipation, anomaly detection techniques have been prevalent. Users' behavior and their impact in energy consumption has deserved special attention, and there are some works aiming at activity recognition for automatic energy management (heating/cooling, lighting) and load shifting.

**Building operation.** Operational data acquired by the building energy management system can be analyzed and exploited to extract patterns describing building operation. In most cases, these patterns are in the form of IF-THEN rules, which can help to generate recommendations for control strategies. Decision trees and association rules have been mostly used in this regard. Similarly, other studies have focused on the improvement of specific components of the building by investigating the relations between control settings and energy usage; e.g. by using regression and neural networks.

**Analysis of infrastructures.** The latest energy efficiency regulations have fostered the study of architectural aspects related to energy use of new and existing buildings. Clustering algorithms have been applied to discover non-obvious factors of energy loss in building infrastructures. Similarly, classification methods have been applied to estimate relevant indicators of thermal behavior and to support decision-making for retrofitting. Some of these works consider time series analysis to enhance the operation of the infrastructures by extracting trends and episodic relationships.

**Economic analysis of electric consumption** Numerous companies have resorted to Data Science in an effort to discover and understand how and when their customers use energy. The techniques traditionally used for this task are classification—to identify common consumption categories—, clustering—for segmenting buildings by their use of the energy—, and pattern analysis—mostly by means of association rules.

Streaming data processing has been also considered for real-time analysis and summarization of energy consumption data.

**Energy fraud detection** Sometimes, energy consumption and services are not appropriately billed because of failures in the measurement equipment. Such failures can either be accidental or the product of fraudulent manipulation. These deviations are commonly referred to as non-technical losses (NTLs), and different techniques have been successfully applied to distinguish legit and fraudulent operation; e.g. tree-based classification, expert systems, association rule extraction and anomaly detection.

### III. DISCUSSION

As extensively discussed in our original paper, the techniques that enable an easy visualization of results, such as classification methods or association rules, have been widely used because they are intuitive and easy to understand. This sometimes leads to a sub-optimal selection of techniques for specific problems (e.g. tree-based classification is the most used method by large), or even to a misuse of the techniques (e.g. clustering instead of classification despite the availability of labelled data). In general, the best results have been achieved by using ensembles. Less used techniques often involve processing streaming data, which are more difficult to process with out-of-the-box algorithms.

As a matter of fact, our revision found that the most frequently used data science algorithms in the energy field are those found in commercial toolboxes, such as *Intelligent Miner*, *SPSS*, *Clementine*, *RapidMiner* and *SAS*. Open platforms, such as *WEKA* and *KNIME*, and programming frameworks, such as *Matlab*, *R* or *Python* are not very popular, because they require specific technical skills and knowledge of the underlying algorithms. Still, they would deserve more attention from the community. We also believe that it is necessary to incorporate to building energy management solutions capabilities for managing big data, particularly by relying on the Apache Spark/Hadoop ecosystem.

### IV. CURRENT TRENDS AND FUTURE CHALLENGES

**Smart metering and Internet of Things.** Smart metering is the continuous monitoring of energy consumption with a view to gaining a better understanding of the energy consumption, generation, and transportation stages. As a result, bills are no longer an aggregated value of energy consumption over a long period of time; they are obtained from real-time measurements. This also enables users to better understand their own energy behavior, which can help to reduce energy waste, and encourages users to modify underperforming habits. It is expected that smart meters, as well as other appliances, will soon be connected to the Internet of Things, and equipped with additional intelligent features. At the same time, device hyperconnection brings security and privacy concerns: a hacker could remotely control the devices and get private details of a home (number of occupants, daily routines, etc.)

**Big Data and Cloud Computing.** The huge amount of data generated by building energy equipment can be exploited to increase energy efficiency, and particularly, smart meters data. This information requires smarter processing, as well as larger and more flexible computational infrastructures. Cloud computing, offering flexible and scalable computational resources, can help to implement Big Data solutions for energy management. It is thus not surprising that large technology corporations are taking an interest in this field, either for the development of energy management solutions for the industry (e.g. Siemens) or to improve their internal energy management procedures (e.g. Google's data centers).

**Privacy and security issues.** New technological advances in massive data processing naturally lead to security and privacy issues. Therefore, it is necessary to develop mechanisms that ensure that the information remains under control according to the legal framework (i.e. the General Data Protection Regulation) and ethical principles. A first step has already been taken by the European Commission regarding smart grids and smart metering in their "Recommendation on the Data Protection Impact Assessment Template for smart grid and smart metering systems", which provides guidelines on how to support the security of the implementation of smart grids and smart metering by data controllers.

### V. CONCLUSION

Our paper reviewed recent developments in Data Science and their influence on Building Energy Management. We examined the usefulness of data science techniques aimed at improving building energy efficiency. Given the progress and the challenges in this area, it is evident that data science techniques will play a key role in the near future.

### ACKNOWLEDGMENT

This work was supported by the University of Granada under the Young Researchers Fellowships Programme (No. P9-2014-ING); the Spanish Ministry for Economy and Competitiveness under the project grant TIN2015-64776-C3-1-R; and the European Union under the project grant Energy IN TIME EeB.NMP.2013-4 (No. 608981).

### REFERENCES

- [1] M. Molina-Solana, M. Ros, M. D. Ruiz, J. Gómez-Romero, and M. J. Martín-Bautista, "Data Science for Building Energy Management: A Review," *Renewable and Sustainable Energy Reviews*, vol. 70, pp. 598–609, 2017.
- [2] WBCSD, "Transforming the market: Energy efficiency in buildings," The World Business Council for Sustainable Development, Tech. Rep., April 2009. [Online]. Available: <http://www.wbcsd.org/transformingthemarketeeb.aspx>
- [3] H. Allcott and S. Mullainathan, "Behavior and energy policy," *Science*, vol. 327, no. 5970, pp. 1204–1205, 2010.
- [4] Z. Li, Y. Han, and P. Xu, "Methods for benchmarking building energy consumption against its past or intended performance: An overview," *Applied Energy*, vol. 124, pp. 325–334, 2014.
- [5] T. Nikolaou, D. Kolokotsa, and G. Stavrakakis, "Review on methodologies for energy benchmarking, rating and classification of buildings," *Advances in Building Energy Research*, vol. 5, no. 1, pp. 53–70, 2011.
- [6] K. Zhou, S. Yang, and C. Shen, "A review of electric load classification in smart grid environment," *Renewable and Sustainable Energy Reviews*, vol. 24, pp. 103–110, 2013.



# Inteligencia Artificial para la Inteligencia Urbana

## Sistema de Ayuda a la Decisión para la predicción de la vulnerabilidad social

Francisco Javier Abarca-Alvarez

Departamento de Urbanística y Ordenación del Territorio  
Universidad de Granada  
Granada, España  
fcoabarca@ugr.es

Francisco Sergio Campos-Sánchez

Departamento de Urbanística y Ordenación del Territorio  
Universidad de Granada  
Granada, España  
scampos@ugr.es

**Resumen**— La vulnerabilidad social desde un punto de vista socio ambiental se enfoca en la identificación de grupos desfavorecidos o vulnerables y de las condiciones de los entornos en los que habita, tratando de determinar los factores que explican la dificultad para afrontar situaciones de desventaja social. Por su complejidad, ligada a la multidimensionalidad, no siempre es sencillo identificar los estratos sociales y urbanos afectados. La investigación pretende evaluar la conexión entre ciertas dimensiones de la vulnerabilidad social y su contexto residencial, creando un Sistema de Ayuda a la Decisión (DSS), útil para la planificación de acciones sociales y urbanas. Para ello se realiza una aproximación holística a la información censal y demográfica habitual en estos estudios, proponiendo la construcción de (i) un modelo de conocimiento basado en Redes Neuronales Artificiales (ANN) del tipo Mapa Auto-organizado (SOM) con el que se identifica y caracteriza un perfil demográfico susceptible de presentar vulnerabilidad social, y (ii) un modelo predictivo de tal perfil basado en reglas a partir de variables residenciales, construido mediante árboles de inferencia condicional. Tales modelos combinados con Sistemas de Información Geográfica (SIG) hacen viable un DSS para la predicción de la Vulnerabilidad Social a partir de información residencial.

**Palabras clave**— Vulnerabilidad Social; Mapa Auto-organizado; árbol de decisión condicional; DSS; Smart City.

### INTRODUCCIÓN

Se suele definir la vulnerabilidad como el potencial de sufrir pérdidas o daños [1], físicos o económicos y localizados en un territorio específico. Cuando se aborda la vulnerabilidad desde un punto de vista social, se enfoca nítidamente en su vertiente humana de aplicación poblacional [2]. En torno al concepto de vulnerabilidad social han aparecido en los últimos años multitud de líneas de trabajo, unas más vinculadas a los riesgos naturales y desastres [3], [4], otras a los factores ambientales [5] y otras más próximas concepto de pobreza [4]. De un enfoque que consideraba fundamentalmente los acontecimientos naturales, se pasó paulatinamente a uno que admitía que los efectos sobre la población estaban condicionados por su capacidad de mitigación [6], en la capacidad de una persona o comunidad para anticipar, resistir y sobreponerse al impacto de acontecimientos imprevistos [7], abriéndose en este sentido a un enfoque que pone en el centro a las personas, siendo aquellas las que tienen o no capacidad de sobreponerse [8] o adaptarse a las vicisitudes, no

exclusivamente vinculadas a los riesgos ambientales, e incluso incorporando una vertiente espacial [9].

La vulnerabilidad social presenta diversos retos como son la multidimensionalidad [4], [5], [10]–[12],[11], [12] o el hecho de que muchas de las variables o dimensiones a evaluar no son directamente observables [10]. Entre las investigaciones que han tratado de identificar indicadores de la vulnerabilidad social destaca el trabajo de Cutter, et al. en el que incorpora como variables del llamado *SoVI*, toda una serie de indicadores como son factores socio-económicos, de edad, indicadores de desarrollo comercial o industrial, desempleo, indicadores de ruralidad, propiedad residencial, nivel de infraestructuras, nivel de rentas, ocupación, acceso a servicios médicos, factores de género, raza y etnia, estructura familiar, nivel educativo, crecimiento vegetativo, dependencia a servicios sociales y presencia de población con necesidades especiales [5].

Con el reto de realizar un Sistema de Ayuda a la Decisión (DSS) en relación a la vulnerabilidad social, se plantea como herramienta necesaria el uso de un Sistema de Información Geográfica (SIG). Tales sistemas han sido usados asiduamente por gobiernos, investigadores y empresas como herramienta de decisión en las que alcanza cierta repercusión e influencia la dimensión espacial [13]. Los SIG surgieron a finales de la década de 1960 desarrollándose especialmente a partir de los 80 [14], y generalizándose su uso a partir de 1990 y especialmente ante el compromiso de convertir tanto a ciudadanos como urbanistas, en actores importantes de la planificación. Es preciso tener presente que los GIS no siempre han estado preparados para cumplir como un DSS en cuanto que deberían integrar realidades y problemas complejos para el apoyo de determinadas decisiones [15], consolidándose como unos sistemas flexibles y resilientes.

Desde su origen la realidad informacional sobre la que se apoyan estos sistemas ha cambiado rápidamente, proliferando la presencia de datos e información espacial de acceso libre, configurándose el campo de los SIG prácticamente como una disciplina, que algunos llaman GISciencia [16], apoyándose en la idea de una nueva Geografía Cuantitativa, fundamentalmente espacial, tendente a la planificación y gestión. Con el tiempo los SIG han pasado del énfasis en la “S” por los problemas computacionales (60-70s), pasando a dedicarse a la “I” por el interés en la información (80-90s), para a partir de 2000

enfocarse en la “G”, ante una necesidad de interpretación geográfica, materializándose en la “sociedad de la información geográfica” y abriendo una nueva etapa para la historia de la Geografía [17]. Es en este punto es cuando singularmente los GIS se aproximan propiamente al concepto DSS.

Frecuentemente esta nueva Geografía Cuantitativa está elevando la granularidad de los datos geográficos hasta el extremo, en una auténtica “n-dimensionalidad” de los datos [18]. En la mayoría de los casos, según Pragya Agarwal y André Skupin, se han enfocado en el análisis estadístico tradicional para resolver problemas de autocorrelación espacial, dejando otros múltiples ámbitos totalmente por explorar. Algunos de esos espacios están siendo abordados por enfoques emergentes como son la Inteligencia Artificial o las Redes Neuronales Artificiales, el aprendizaje automático (*Machine Learning*) o de forma específica por la Geo-computación. Estas nuevas técnicas y enfoques están propiciando un cambio de paradigma en los DSS, considerándose que en la actualidad pueden ser útiles para la comprensión de la realidad, detección de sus problemas, y en definitiva la formulación de nuevas hipótesis y no solo como instrumento para verificar aquellas previamente establecidas.

Como objetivo principal la investigación se propone evaluar la viabilidad de la construcción de un modelo de vulnerabilidad social, a priori complejo, a partir de un modelo residencial, del que es más sencillo tener información. Para ello se utilizarán técnicas de interpretación de la realidad mediante Inteligencia Artificial y *Machine Learning* apoyados en SIG. De forma específica para la validación de la metodología propuesta se caracterizará la vulnerabilidad social de la población de Andalucía a partir de información residencial en la que reside la misma.

Para alcanzar tal objetivo la investigación se enmarca en los paradigmas de los DSS orientados al conocimiento y orientados a los modelos [19]. El primer paradigma se enfoca en la construcción de un sistema de descubrimiento de conocimiento basado en bases de datos institucionales sobre las cualidades demográficas y sociales de Andalucía (Fase de modelado 1 de la metodología); y en el segundo paradigma (Fase de modelado 2 de la metodología) se enfatiza el acceso, la manipulación y creación de un modelo cuantitativo de la realidad social, orientado a proporcionar apoyo a la decisión, elaborado a partir de la realidad residencial de los territorios en estudio. Los DSS usan datos y parámetros proporcionados por los agentes de decisión para ayudarles a analizar una situación, aunque no tienen por qué ser datos masivos [19]. En nuestro caso el modelo se construye con datos masivos (tanto demográficos como residenciales), pero puede ser usado para la toma de decisiones con una información muy limitada, incluso escasa.

La investigación, tal y como se ha avanzado, consiste en la construcción de dos modelos vinculado con herramientas procedentes de las Tecnologías de la Información [20]:

#### *Descubrimiento de conocimiento y clasificación mediante aprendizaje no supervisado. Los Mapas Auto-organizados (SOM)*

En la investigación se recurrirá a técnicas de lo que se viene a conocer como Mapas Auto-organizados, en adelante SOM. Fueron propuestos inicialmente por Teuvo Kohonen [21]–[23]. La metodología SOM es una técnica descubrimiento de conocimiento o de minería de datos consistente en una Red Neuronal Artificial. Procede del campo de conocimiento de la Inteligencia Artificial, habiéndose mostrado muy eficaz y robusta en numerosas disciplinas, presentando diversas capacidades entre las que podemos destacar inicialmente dos: (i) es capaz de mostrar y visualizar la información de partida de forma clara y ordenada, (ii) permite clasificar y por lo tanto etiquetar los sujetos en estudio en clases que no requieren su definición, caracterización o etiquetado nominativo previo (aprendizaje no supervisado). Frente a otras metodologías de descubrimiento de patrones, como por ejemplo el análisis clúster, la metodología SOM, tiene la ventaja de (i) permitir visualizar un gran conjunto de datos estadísticos [24], (ii) mostrar las relaciones topológicas de similitud o de diferencia entre los sujetos en estudio, (iii) ser interpretables gráficamente y (iv) constituir por sí mismo un sistema de conocimiento de ayuda a la decisión para el análisis y visualización de indicadores estadísticos [24].

Mediante estas técnicas se obtendrá por un lado el etiquetado a modo de clases o perfiles de los diferentes fragmentos de territorio andaluz estudiado, atendiendo al análisis multi-variable de los atributos demográficos y sociales estudiados. Se alcanza asimismo un sistema de análisis e interpretación de las clases obtenidas, facilitado por la metodología SOM, materializado en cartografías temáticas de los diferentes atributos incluidos en la red neuronal y en diferentes tablas y datos estadísticos que permiten conocer las características diferenciadoras de cada perfil. Para facilitar su utilización como parte de un DSS se representan tales clases, y en especial la clase o categoría de vulnerabilidad social mediante GIS.

#### *Construcción de modelos predictivos mediante aprendizaje supervisado. Árboles de decisión*

Mediante un proceso de *Machine Learning* se obtendrán una serie de reglas que permitan predecir las clases o perfiles que se determinaron con el modelo SOM, utilizando para ello únicamente atributos sobre la realidad residencial de los territorios en estudio. Estas variables residenciales no se tuvieron en consideración en la creación y constitución de la red neuronal SOM ni consecuentemente pudieron afectar o correlacionarse en la definición de los perfiles obtenidos por aquella. Se realiza una aproximación al problema de aprendizaje mediante el paradigma “divide y vencerás”, que al realizarse sobre un conjunto de instancias independientes, conduce naturalmente a un estilo de representación llamado árbol de decisión [25]. En cada nodo del árbol interviene un atributo en particular, comparándose normalmente cada instancia del atributo con el valor de una constante, y generándose normalmente dos ramas atendiendo a las instancias que cumplen o no tal regla. El árbol supone una representación asequible para interpretar y usar en la



predicción de la realidad demográfica y social de un territorio y consecuentemente útil para la toma de decisiones sobre el mismo, usando para ello una información limitada y generalmente de fácil y económica obtención sobre la realidad residencial del lugar en estudio. Asimismo al evaluar el “valor” de los perfiles alcanzados en la Fase 1, en su caracterización espacial mediante SIG, se verifica la utilidad de la metodología propuesta.

## MATERIALES Y MÉTODOS

### *Metodología de investigación*

Para la óptima comprensión y para la obtención de los mejores resultados del DSS se siguen las siguientes fases [26]: (i) información y funciones de procesado, (ii) conjuntos de datos, (iii) modelos, y (iv) representaciones visuales.

#### *1) Información y funciones de procesado:*

La información utilizada en la investigación procede del Censo de Población 2001 de Andalucía obtenidos por el Instituto de Estadística y Cartografía de Andalucía (IECA). Sobre esta información se ha realizado una intensa preparación de datos con la integración y limpieza de datos, transformación de atributos mediante la creación de indicadores agregados que sintetice forma objetiva y compacta las principales cualidades demográficas de los datos originales. Debido a la robustez de los SOM, no es necesario realizar su tipificación o normalización [27] previamente a la agregación e incorporación al modelo.

*a) Instancias:* La unidad de territorio sobre la que se obtienen los datos, es la Sección Censal, alcanzándose la totalidad de las 5381 secciones censales de Andalucía, quedando representada la totalidad de la superficie y de población censada en la región andaluza, no realizándose muestreo alguno.

*b) Atributos:* De los indicadores de Vulnerabilidad Social “SoVI” [5], se incorporan factores socio económicos, de edad, indicadores de desarrollo comercial o industrial (empleo por sectores), desempleo, indicadores de ruralidad (empleo sector agrario), propiedad residencial, nivel de infraestructuras, nivel de rentas (aunque conectado a nivel de ocupación), ocupación, acceso a servicios médicos, y no se incorporan factores de género, raza y etnia, estructura familiar, nivel educativo, crecimiento vegetativo, dependencia a servicios sociales o presencia de población con necesidades especiales. Los atributos que se han usado en la Fase de modelado 2 están compuestos de variables de la dimensión residencial.

#### *2) Conjuntos de datos:*

Se opera inicialmente con dos bases de datos desconectadas: una propia de la Fase de modelado 1, con dimensión principalmente demográfica y social y otra propia para la Fase de modelado 2, basada en la dimensión residencial. El funcionamiento será fundamentalmente independiente, conectándose únicamente tras el Modelado 1 para evaluar cómo se ajustan los perfiles de vulnerabilidad social y para la construcción del árbol de decisión.

#### *3) Modelos:*

Tal y como se ha avanzado distinguimos entre dos fases de modelado:

*a) Fase de modelado 1:* Modelo de clasificación y conocimiento. Entre sus objetivos tenemos por un lado, la clasificación y etiquetado de los datos de la dimensión demográfica y social, tal y como se han identificado anteriormente. En esta fase se usará una red neuronal artificial y específicamente un SOM. Esta metodología en cuanto que no supervisada, permite clasificar (propriadamente segmentar) sin atribuir a priori una etiqueta con definiciones y significados previamente atribuidos, siendo útil para reducir la enorme complejidad de los datos [28].

Para facilitar la comprensión de los perfiles obtenidos se caracteriza a cada clúster con sus estadísticos básicos como son la Media, la Desviación Estándar, el Máximo y el Mínimo [29], tratando de conseguir principalmente dos resultados adicionales, i) el factor o variable que es más importante para el efecto y ii) el valor de tal factor [30]. Para el análisis de los perfiles además de la información estadística que los define, son valiosos los Mapas SOM monovariantes ya que permiten según la distribución de valores en el mismo, evaluar relaciones y correlaciones entre variables.

Para cumplir con las recomendaciones de la *American Statistical Association* [31], para cada variable y perfil, además de la significación estadística, se calcula su tamaño del efecto [32].

*b) Fase de modelado 2:* Modelo de predicción. Para la construcción del modelo que permita predecir la vulnerabilidad, se realiza un árbol de decisión basado en reglas, identificando mediante la representación de condiciones sucesivas, el grado de probabilidad de existir el patrón de vulnerabilidad obtenido en la fase de modelado 1. Para ello se ha realizado la partición de los datos en 70/30 (entrenamiento/prueba); y se han usado los árboles de inferencia condicional, basado en el test de permutación [33], utilizando pruebas no paramétricas como criterios de división de las ramas, no precisando poda de las mismas. Para ello se ha usado el paquete “rpart” del software estadístico R-Project [34], usando como parámetros: división mínima=20, profundidad máxima=2, y cubo mínimo=7.

*4) Representaciones visuales:* Una de las cualidades que presentan las cartografías SOM es la capacidad de representación de la información resultante de un modo relativamente sencillo de comprender, al mostrar una representación bidimensional de las instancias de partida, con la característica de que cada una de ellas tiene por “vecina” la instancia con cualidades más semejantes. En la misma cartografía se suele representar las agrupaciones de las instancias en los distintos perfiles conformados. Esta representación se suele completar con un mapa por cada uno de los atributos o variables que construyeron el mapa SOM. Finalmente se representarán espacialmente tales perfiles mediante GIS y se obtendrán los gráficos de los árboles de decisión.

RESULTADOS

Según la metodología se realizan las tareas propias de los apartados 1) y 2), obteniéndose dos bases de datos independientes. Se puede observar una síntesis descriptiva de tales variables de partida en las 3 primeras columnas de la Tabla 1 para los datos principalmente demográficos y de la

Tabla 1. Variables de las dimensiones demográfica, social, laboral, de los equipamientos y de los servicios. Se muestra el Perfil (4) con rasgos de vulnerabilidad social. conf: Confianza p-valor: ns: p>0.05; \*: p<=0.05; \*\* p<=0.01; \*\*\*: p<=0.001. TE:Tamaño del Efecto. +++: Grande positivo; ++:Mediano positivo; +:Pequeño positivo; ---: Grande negativo; --:Mediano negativo; -:Pequeño negativo.

N de instancias (%)	Muestra completa		Perfil 4			
	5381	100.00	550		10.22%	
Atributo	Media	DS	Media	DS	conf	TE
2.1_EquipSaludPor1000Hab	1.39	6.16	1.56	2.45	ns	
2.1_EquipEducacionPor1000Hab	1.14	2.36	2.16	3.20	***	+
2.1_EquipBienestarPor1000Hab	0.83	1.68	1.85	3.77	***	++
2.1_EquipCulDepPor1000Hab	0.72	1.47	1.94	3.07	***	+++
2.1_EquipamientosPor1000Hab	4.08	8.31	7.51	7.25	***	+
2.2_%NoAguaCorriente	0.91	2.84	3.16	6.47	***	++
2.2_%Gas	22.77	33.76	12.31	28.29	***	-
2.2_%Telefono	86.96	17.48	63.45	23.69	***	---
2.5_%PocaLimpiezaCalles	35.10	19.82	21.23	22.00	***	---
2.6_%Delincuencia	25.32	23.67	4.94	10.62	***	---
3.1_Poblacion	1367	518.00	900.20	410.50	***	---
3.1_EdadMediaPoblacion	38.01	4.41	42.74	4.02	***	+++
3.1_%Nacimientos	11.32	3.21	9.54	2.78	***	---
3.2_PersonasPorEdificio	14.46	22.91	2.43	3.79	***	---
3.2_%Hogares1Adulto	18.80	7.55	27.87	7.37	***	+++
3.2_%Hogares1adultoYMenor	1.83	1.12	1.28	0.92	***	-
3.2_%Hogares2adulto	41.24	6.75	41.01	5.11	ns	
3.2_%Hogares3adulto	18.41	3.36	16.53	3.13	***	---
3.2_%Hogares4adulto	19.71	6.64	13.32	4.70	***	---
3.2_Hogares	449.20	167.50	340.20	145.70	***	---
3.2_HabitantesPorHogar	3.04	0.36	2.62	0.31	***	---
3.2_RatioEdifViviendasPorHogar	0.74	0.56	1.42	0.48	***	+++
3.3_%PoblacionArraigada	80.11	9.49	82.19	5.00	***	+
3.3_%PoblacionInmigranteProvincial	3.87	5.81	3.83	3.52	ns	
3.3_%PoblacionInmigranteRegional	1.35	1.28	0.97	1.09	***	-
3.3_%PoblacionInmigranteNacional	1.58	1.33	1.89	1.59	***	+
3.3_%PoblacionInmigranteExtranjero	1.32	2.79	1.13	1.95	*	
3.3_%España	97.92	4.58	98.58	2.68	***	
3.3_%EuropaUE	0.77	2.97	0.82	2.21	ns	
3.3_%EuropaNoUE	0.18	0.56	0.12	0.38	***	
3.3_%AmericaDelNorte	0.05	0.18	0.02	0.08	***	
3.3_%AmericaCentral	0.04	0.09	0.01	0.05	***	-
3.3_%AmericaDelSur	0.41	0.83	0.20	0.47	***	-
3.3_%Asia	0.08	0.34	0.02	0.12	***	
3.3_%Africa	0.54	2.01	0.23	1.05	***	
3.3_%Oceania	0.00	0.02	0.00	0.01	***	
3.3_%Apatridas	0.00	0.01	0.00	0.00	***	
3.4_%TrabajaEnProvincia	6.43	5.48	6.81	4.43	*	
3.4_%TrabajaEnRegion	0.87	1.00	0.98	0.95	**	
3.4_%TrabajaEnEspaña	0.47	0.57	1.00	1.26	***	+++
3.4_%TrabajaOtroPais	0.12	0.29	0.16	0.53	ns	
4.1_%Ocupados	33.19	6.51	27.38	7.11	***	---
4.1_%Parados	10.48	5.11	12.95	7.53	***	+
4.1_%Inactivos	38.02	7.24	43.94	7.25	***	+++
4.2_LocalComercialPor1000Hab	26.90	98.90	19.40	20.90	***	
4.2_OficinaYServiciosPor1000Hab	10.70	44.60	8.10	12.20	***	
4.2_Industrial1000Hab	3.07	12.11	3.63	7.94	ns	
4.2_LocalAgrario1000Hab	0.65	6.71	3.14	19.84	**	+
4.2_LocalInactivoPor1000Hab	13.37	20.22	19.63	29.47	***	+
4.3_EstadoConstruccionesD	0.40	0.23	0.50	0.21	***	+
4.4_IDH_COMBINADO-	0.00	0.00	0.00	0.00	***	+
4.4_IDH_COMBINADO+	0.00	0.00	0.00	0.00	ns	
4.4_IDH_COMBINADO	0.00	0.00	0.00	0.00	***	+
4.5_%AgriculturaGanaderia	4.16	6.06	7.28	5.74	***	++
4.5_%Pesca	0.14	0.59	0.03	0.12	***	
4.5_%Industria	3.81	2.46	2.81	2.18	***	-
4.5_%Construccion	4.47	2.44	4.35	2.08	ns	
4.5_%Servicios	20.61	8.12	12.91	4.83	***	---
4.5_%Paro	24.09	11.26	31.61	16.40	***	++
4.6_%ViviendaEnPropiedad	82.28	13.30	82.73	10.10	ns	
4.6_%ViviendasEnAlquiler	9.39	11.29	5.05	5.16	***	-

Tabla 2. Variables de la dimensión residencia. Se muestra el Perfil (4) con rasgos de vulnerabilidad social. Téngase en cuenta que esta información no ha intervenido en la constitución del perfil. conf: Confianza p-valor: ns: p>0.05; \*: p<=0.05; \*\* p<=0.01; \*\*\*: p<=0.001. TE:Tamaño del Efecto. +++: Grande positivo; ++:Mediano positivo; +:Pequeño positivo; ---: Grande negativo; --:Mediano negativo; -:Pequeño negativo.

N de instancias (%)	Muestra completa		Perfil 4			
	5381	100.00	550		10.22%	
Atributo	Media	DS	Media	DS	conf	TE
2.3_%Garaje	19.03	18.79	16.70	14.07	***	
2.4_%NoAccesible	72.81	30.40	87.94	22.67	***	+
4.3_EdadMediaConstruccionesM	1963	20.00	1943	28.10	***	---
4.3_EdadMediaConstruccionesD	23.38	14.79	37.01	14.78	***	+++
4.3_EstadoConstruccionesM	1.16	0.21	1.23	0.20	***	+
5.1_%RuidosExteriores	32.53	18.35	13.15	15.83	***	---
5.1_%Contaminacion	19.47	14.83	8.11	11.66	***	---
6.1_AlturaMediaConstruccionesM	2.68	1.60	1.70	0.51	***	---
6.1_AlturaMediaConstruccionesD	5.46	5.27	1.94	1.34	***	---
6.2_EdifViviendas	327.50	292.70	460.10	225.30	***	+
6.2_%Unifamiliares	61.10	33.88	87.48	13.05	***	++
6.2_%UnifamiliaresAgrupadas	21.66	21.86	8.52	8.70	***	---
6.2_%UnifamiliaresConLocales	17.04	24.09	3.94	6.38	***	---
6.2_%Plurifamiliares	0.20	0.80	0.06	0.20	***	
6.2_%EdifLocalesConAlgunaVivienda	0.80	2.59	0.24	0.74	***	-
6.2_%EdifLocales	8.93	19.87	6.95	7.79	***	
6.2_%EdifAlojamientos	0.08	1.05	0.22	1.79	ns	
6.3_%MalasComunicaciones	13.95	15.95	15.06	20.53	ns	
6.4_%PocasZonasVerdes	48.85	25.97	37.60	31.06	***	-
6.5_%FaltaAseosEnViviendas	1.32	2.95	2.20	5.11	***	+

Tabla 2 para la dimensión residencial. Siguiendo con el apartado 3) de la metodología, se lleva a cabo la Fase de modelado 1 usando para ello 63 variables de la dimensión demográfica, social, laboral, de los equipamientos y de los servicios, obteniéndose los perfiles que caracterizan la realidad demográfica y parte de las dimensiones de vulnerabilidad social.

Se puede observar lo siguiente en el Perfil 4 (Tabla 1): El análisis estadístico desvela que este perfil poblacional presenta una elevada edad media, gran cantidad de hogares con un único ocupante, abundancia de viviendas vacías y con ciertos problemas como carencia de agua corriente en proporción mayor que el resto. Curiosamente la estadística delata que habitan en asentamientos con buenos ratios de equipamientos culturales y de bienestar por población, probablemente derivado del bajo número de habitantes de tales poblaciones y una aceptable distribución de tales funciones. Espacialmente se observa que corresponden con los emplazamientos rurales más aislados y a mayor distancia de las principales ciudades. Comparando este perfil con el Perfil 2, se observa que coincide con una población rural más envejecida, que en muchas ocasiones vive sola, en entornos urbanos con poca población, con poca ocupación de las viviendas y con altos índices de analfabetismo, paro e inactividad. Mediante la representación GIS (Fig. 1), se localiza en este perfil entornos de la Hoya de Baza (Granada), los Campos de Tabernas (Almería), altos de la Sierra de Gádor (Almería), la Sierra de Aracena (Huelva), etc.

A continuación en la Fase de modelado 2 se obtiene el árbol que permite “predecir” cómo identificar el Perfil 4, es decir, se trata de identificar las cualidades residenciales del perfil poblacional con muestras de vulnerabilidad social. En

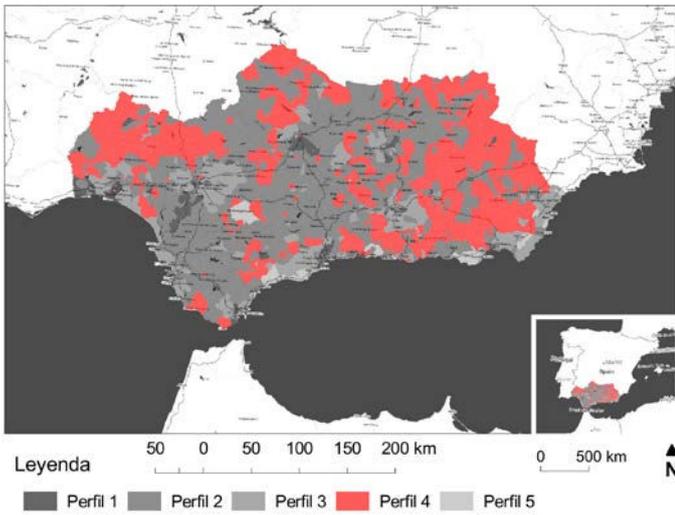


Fig. 1. Representación SIG de la clasificación generada mediante SOM. Se observa el Perfil 4 que coincide con los rasgos de vulnerabilidad.

realidad mediante los árboles de decisión se obtiene la probabilidad de identificar correctamente el Perfil 4 a partir de un número de variables muy reducido (Fig. 2). Finalmente se evalúa el rendimiento del modelo de árbol condicional de clasificación mediante la curva ROC (Fig. 3), obteniéndose un AUC=0.78.

DISCUSIÓN Y CONCLUSIONES

A partir del análisis de las experiencias bibliográficas de aplicación del modelo de clasificación y conocimiento mediante la metodología SOM y corroborado mediante la propia experiencia llevada a cabo, se puede concluir que la metodología SOM es útil para realizar un análisis exploratorio [28], con clasificaciones más potentes y robustas que las técnicas descriptivas tradicionales [35], alcanzándose una comprensión de tales patrones y su distribución espacial [29], explorándose visualmente y validándose eficazmente gracias a las consistentes propiedades geométricas de los resultados de los SOM [36], [37] y permitiendo finalmente identificar, mediante el análisis del tamaño del efecto, un perfil en el

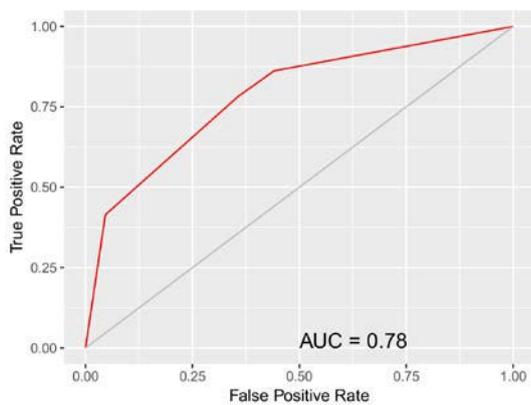


Fig. 3. Curva ROC de rendimiento del modelo Árbol de decisión condicional de pertenencia al Perfil 4 de vulnerabilidad social. El Modelo obtiene un área bajo curva (AUC) de 0.78.

territorio andaluz con clara asociación con la vulnerabilidad social. Esta asociación tiene como la utilidad permitir la formación de un DSS y en lo que venimos a llamar “Inteligencia Urbana” en cuanto que facilita afrontar mejores decisiones en la planificación, el diseño y la política urbana.

Por su lado, la metodología basada en árboles de decisión a partir de una clasificación SOM se considera útil para: atribuir de forma sencilla patrones de comportamiento que pueden ser extremadamente complejos; y predecir de forma eficaz comportamientos de variables que presentan cierto coste o dificultad de evaluación, como son las variables demográficas o sociales, a partir de otras variables con menor complejidad y coste de evaluación, como las variables residenciales.

Sin embargo, es necesario tener presente ciertas precauciones y limitaciones en el uso de estas metodologías y en su implementación concreta. Entre ellas destacan que los datos usados pueden encontrarse ya obsoletos, y que no han quedado representadas absolutamente todas las dimensiones de la vulnerabilidad social [5]. Por otro lado un análisis de la población de una sección censal no es propiamente un análisis de la población, y debe extremarse la precaución y limitar la inferencia a la escala de la observación, no alcanzando directamente a los individuos [28], es decir no se debe extrapolar a individuos las conclusiones obtenidas del estudio de grupos de individuos.

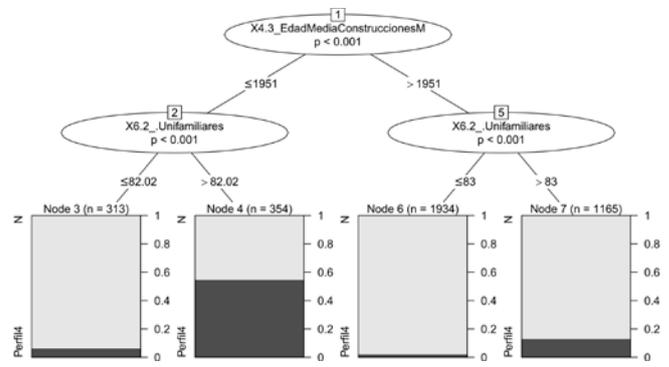


Fig. 2. Árbol de decisión. La variable que se predice es la pertenencia al Perfil 4 que se ha conectado con los rasgos de vulnerabilidad social.

Mediante la investigación aplicada al caso de estudio de la región de Andalucía, se ha obtenido un árbol de decisión de predicción del modelo obtenido mediante una metodología de clasificación no supervisada con Mapas auto-organizados, técnicas que han demostrado ser sencillas de usar, a la vez que útiles y capaces de predecir, con un relativo bajo error, fenómenos demográficos complejos y relevantes, como es la vulnerabilidad social. Para tal predicción se utiliza exclusivamente información de la realidad residencial.

En el caso específico de estudio, se han detectado gráficamente las áreas de Andalucía en las que se pronostica que pudieran estar afectadas por vulnerabilidad social, evidenciándose lo que podría nombrarse como “otra Andalucía”, una Andalucía eminentemente rural, con signos de aislamiento frente a las oportunidades de empleabilidad, etc. que ofrecen las ciudades. Las áreas urbanas enmarcadas en el

perfil de vulnerabilidad social son ciertamente escasas. Esto podría ser una debilidad del modelo, siendo recomendable un ajuste del mismo que modifique el umbral de vulnerabilidad y que englobe así ámbitos que el estado del arte identifica como tales. Por su lado el árbol de decisión obtenido resulta interesante en cuanto que permite, de forma sencilla y con cierto nivel de precisión, predecir la probabilidad de que los habitantes de un área son vulnerables sociales, utilizando para ello un escaso número de variables. Específicamente en la región de estudio, se observa que únicamente con la edad de las edificaciones y la cantidad de vivienda unifamiliar del lugar en estudio es posible predecir la pertenencia a un perfil urbano afín a situaciones de vulnerabilidad social, con una probabilidad que se puede evaluar con el indicador AUC=0.78.

Se puede por lo tanto concluir que existe una conexión y relación entre los fenómenos demográficos y de vulnerabilidad y la configuración residencial de Andalucía, debiendo ser cauto y evitar a priori un establecimiento causa-efecto entre tales fenómenos, que requerirían otras pruebas diferenciadas que distan de ser el objetivo de esta investigación.

#### AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por el Plan Propio de Investigación 2016 de la Universidad de Granada PP2016-PIP09.

#### REFERENCIAS

[1] S. L. Cutter, «Vulnerability to hazards», *Prog. Hum. Geogr.*, vol. 20, n.º 4, pp. 529-539, 1996.

[2] B. Wisner, P. Blaikie, T. Cannon, y I. Davis, *At Risk: Natural Hazards, People's Vulnerability, and Disasters*. New York: Routledge, 2004.

[3] A. Ebert, N. Kerle, y A. Stein, «Urban social vulnerability assessment with physical proxies and spatial metrics derived from air- and spaceborne imagery and GIS data», *Nat. Hazards*, vol. 48, n.º 2, pp. 275-294, 2009.

[4] M. Prowse, *Towards a Clearer Understanding of 'Vulnerability' in Relation to Chronic Poverty*, n.º 24, 2003.

[5] S. L. Cutter, B. J. Boruff, y W. L. Shirley, «Social vulnerability to environmental hazards», *Soc. Sci. Q.*, vol. 84, n.º 2, pp. 242-261, 2003.

[6] D. Sánchez-González y C. Egea-Jiménez, «Enfoque de vulnerabilidad social para investigar las desventajas socioambientales. Su aplicación en el estudio de los adultos mayores», *Papeles de población*, vol. 17, n.º 69, pp. 151-185, 2011.

[7] P. Blaikie, T. Cannon, I. Davis, y B. Wisner, «Vulnerabilidad. El Entorno Social, Político y Económico de los Desastres», *Prim. Edición Julio 1996*, p. 292, 1996.

[8] CEPAL-ELAC, «Vulnerabilidad Sociodemográfica: viejos y nuevos riesgos para comunidades, hogares y personas.», Brasilia, 2002.

[9] H. Gu, S. Du, B. Liao, J. Wen, C. Wang, R. Chen, y B. Chen, «A hierarchical pattern of urban social vulnerability in Shanghai, China and its implications for risk management», *Sustain. Cities Soc.*, vol. 41, n.º March, pp. 170-179, 2018.

[10] E. Tate, «Social vulnerability indices: A comparative assessment using uncertainty and sensitivity analysis», *Nat. Hazards*, vol. 63, n.º 2, pp. 325-347, 2012.

[11] Y. N. Maharani, S. Lee, y S. J. Ki, «Social vulnerability at a local level around the Merapi volcano», *Int. J. Disaster Risk Reduct.*, vol. 20, n.º July, pp. 63-77, 2016.

[12] Y. N. Maharani y S. Lee, «Assessment of social vulnerability to natural hazards in South Korea: case study for typhoon hazard», *Spat. Inf. Res.*, vol. 25, n.º 1, pp. 99-116, 2017.

[13] S. Jarupathirun y F. Zahedi, «GIS as Spatial Decision Support Systems», en *Geographic information systems in business*, J. B.

Pick, Ed. Idea Group Pub, 2005.

[14] A. G.-O. Yeh, «Urban planning and GIS», *Geogr. Inf. Syst. Princ. Tech. Manag. Appl.*, 2005.

[15] P. G. W. Keen, «Decision support systems: The next decade», *Decis. Support Syst.*, vol. 3, n.º 3, pp. 253-265, sep. 1987.

[16] C. Yang, R. Raskin, M. Goodchild, y M. Gahegan, «Geospatial Cyberinfrastructure: Past, present and future», *Comput. Environ. Urban Syst.*, vol. 34, n.º 4, pp. 264-277, 2010.

[17] G. D. Buzai, G. Cacace, L. Humacata, y S. L. Lanzelotti, *Teoría y métodos de la geografía cuantitativa: libro 1: por una geografía de lo real*, n.º 1, 2015.

[18] P. Agarwal y A. Skupin, *Self-Organising Maps: Applications in Geographic Information Science*. John Wiley & Sons, Ltd, 2008.

[19] D. J. Power, R. Sharda, y F. Burstein, «Decision Support Systems», en *Wiley Encyclopedia of Management*, C. L. Cooper, Ed. Chichester, UK: John Wiley & Sons, Ltd, 2015, pp. 1-4.

[20] F. J. Abarca-Alvarez, F. S. Campos-Sánchez, y R. Reinoso-Bellido, «Methodology of Decision Support through GIS and Artificial Intelligence: Implementation for Demographic Characterization of Andalusia based on Dwelling», *Estoa*, vol. 6, n.º 11, pp. 33-51, 2017.

[21] T. Kohonen, «The Self-Organizing Map», en *Proceeding of the IEEE*, 1990, vol. 78, pp. 1464-1480.

[22] T. Kohonen, «The self-organizing map», *Neurocomputing*, vol. 21, n.º 1-3, pp. 1-6, 1998.

[23] H. Ritter y T. Kohonen, «Self-organizing semantic maps», *Biol. Cybern.*, vol. 61, n.º 4, pp. 241-254, 1989.

[24] S. Kaski y T. Kohonen, «Exploratory Data Analysis By The Self-Organizing Map: Structures Of Welfare And Poverty In The World (1996)», *Neural Networks Financ. Eng. Proc. Third Int. Conf. Neural Networks Cap. Mark.*, pp. 498-507, 1996.

[25] I. H. Witten, E. Frank, y M. a Hall, *Data Mining: Practical Machine Learning Tools and Techniques (Google eBook)*, 2011.

[26] M. S. Silver, «On the Design Features of Decision Support Systems: The Role of System Restrictiveness and Decisional Guidance», en *Handbook on Decision Support Systems 2: Variations*, F. Burstein y C. W. Holsapple, Eds. Springer-Verlag Berlin Heidelberg, 2008, pp. 261-291.

[27] P. Demartines y F. Blayo, «Kohonen Self-Organizing Maps: Is the Normalization Necessary?», *Complex Syst.*, vol. 6, n.º 2, pp. 105-123, 1992.

[28] S. E. Spielmans y J.-C. Thill, «Social area analysis, data mining, and GIS», *Comput. Environ. Urban Syst.*, vol. 32, n.º 2, pp. 110-122, 2008.

[29] L. Faggiano, D. de Zwart, E. García-Berthou, S. Lek, y M. Gevrey, «Patterning ecological risk of pesticide contamination at the river basin scale», *Sci. Total Environ.*, vol. 408, n.º 11, pp. 2319-2326, 2010.

[30] P. K. Wu y T. C. Hsiao, «Factor Knowledge Mining Using the Techniques of AI Neural Networks and Self-Organizing Map», *Int. J. Distrib. Sens. Networks*, vol. 2015, 2015.

[31] R. L. Wasserstein y N. A. Lazar, «The ASA's statement on p-values: context, process, and purpose», *Am. Stat.*, vol. 1305, n.º April, pp. 00-00, 2016.

[32] R. Coe y C. Merino, «Magnitud del efecto: Una guía para investigadores y usuarios», *Rev. Psicol.*, vol. 21, n.º 1, pp. 147-177, 2003.

[33] H. Strasser y C. Weber, «On the Asymptotic Theory of Permutation Statistics», *Math. Methods Stat.*, vol. 8, pp. 220-250, 1999.

[34] T. Hothorn, K. Hornik, y A. Zeileis, «Unbiased recursive partitioning: A conditional inference framework», *J. Comput. Graph. Stat.*, vol. 15, n.º July, pp. 651-674, 2006.

[35] R. Hamaina, T. Leduc, y G. Moreau, «Towards Urban Fabrics Characterization based on Buildings Footprints», en *Bridging the Geographic Information Sciences*, J. Gensel, Ed. 2012, pp. 231-248.

[36] F. J. Abarca-Alvarez y F. Osuna-Pérez, «Cartografías semánticas mediante redes neuronales: los mapas auto-organizados (SOM) como representación de patrones y campos», *EGA. Rev. expresión gráfica Arquít.*, vol. 18, n.º 22, 2013.

[37] J. Yan y J.-C. Thill, «Visual data mining in spatial interaction analysis with self-organizing maps», *Environ. Plan. B Plan. Des.*, vol. 36, n.º 3, pp. 466-486, 2009.

**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 4:  
OPTIMIZACIÓN Y  
COMPUTACIÓN DE  
ALTAS PRESTACIONES







# La importancia de un aplicativo web como ayuda para la conformación de grupos de trabajo colaborativo

Franco Esteban Córdoba Pérez  
Universidad de Nariño  
San Juan de Pasto, Colombia  
franco12594@udenar.edu.co

Oscar Revelo Sánchez  
Universidad de Nariño  
San Juan de Pasto, Colombia  
orevelo@udenar.edu.co

Alexander Barón Salazar  
Universidad de Nariño  
San Juan de Pasto, Colombia  
abaron\_98@udenar.edu.co

**Resumen**– En este artículo se describe la importancia que tiene una herramienta web como ayuda en la conformación de grupos de trabajo colaborativo donde se busca que estos sean de igual tamaño y equitativos respecto a más de un atributo, siendo este un paso importante y complejo para diseñar actividades eficaces de trabajo colaborativo. Dando paso a una solución sistematizada debido a que la búsqueda exhaustiva no siempre será conveniente debido a la explosión combinatoria que puede presentarse, se propone una herramienta basada en algoritmos genéticos donde intervienen los diferentes tipos de operadores genéticos para el proceso de selección hasta dar con una solución satisfactoria.

**Palabras clave**-- Herramienta web, agrupamiento, trabajo colaborativo, algoritmos genéticos.

## I. INTRODUCCIÓN

La calidad y la mejora continua son los pilares fundamentales en el progreso de diferentes áreas, como lo pueden ser las áreas laborales o de educación. Debido a esto se deben buscar nuevas estrategias para la mejora, una de estas es el trabajo colaborativo que se define como una estrategia de cooperación y aprendizaje en grupos de trabajo, en donde se organizan pequeños grupos en los que cada miembro tiene objetivos en común que han sido establecidos previamente y sobre los cuales se realizará el trabajo, en oposición al trabajo individual y competitivo de partes separadas de miembros.

La formación de grupos es un paso importante y complejo para diseñar actividades eficaces de trabajo colaborativo. A través de la selección adecuada de los individuos a un grupo, es posible crear ambientes que favorezcan la aparición de interacciones significativas, y, por lo tanto, aumentar el aprendizaje sólido, el crecimiento intelectual y la correcta elaboración de una labor.

Debido a que el trabajo colaborativo puede ser usado en diferentes ámbitos existen diferentes tipos y cantidad de características que pueden ser evaluadas para la conformación de grupos como lo pueden ser habilidades laborales, estilos de aprendizaje, calificaciones, rasgos de personalidad, y así sucesivamente, debido a esto existirán muchas combinaciones para formar grupos dando lugar a espacios de búsqueda muy grandes por lo que no se podría formar grupos mediante técnicas determinísticas. Para la solución de este tipo de problemas destacan los Algoritmos Evolutivos que han demostrado ser especialmente adecuados para problemas

combinatorios y dentro de estos los Algoritmos Genéticos los cuales simulan en un computador el proceso de selección del “más apto” obteniendo así la población más óptima según los criterios de selección.

En el presente artículo se presenta una investigación que busca mostrar la importancia de una herramienta de agrupamiento para la conformación de grupos de trabajo colaborativo, basándose en diferentes características de los integrantes para poder conformar grupos heterogéneos utilizando como técnica de agrupamiento y de optimización los algoritmos genéticos. El resto del artículo está dividido de la siguiente forma: En la siguiente sección se aborda el marco teórico donde se hablara del trabajo colaborativo, algoritmos genéticos y antecedentes que tienen relación con la investigación. En la sección posterior se describe el modelo propuesto para la conformación de grupos y la herramienta de agrupamiento desarrollada aplicando este modelo. Luego se da a conocer los resultados obtenidos mediante varias pruebas. Finalmente se presentan las conclusiones.

## II. MARCO TEÓRICO

### A. Trabajo Colaborativo

El trabajo colaborativo se define como aquellos procesos intencionales de un grupo para alcanzar objetivos específicos, siendo una metodología de enseñanza y de realización de la actividad laboral basada en la creencia que el aprendizaje y la actividad laboral se incrementa cuando se desarrollan destrezas cooperativas para aprender y solucionar los problemas y acciones en las cuales los individuos se ven inmersos. [1] Este combina el trabajo individual dentro de un grupo de trabajo para lograr un objetivo común, en condiciones en las que todos los miembros deben cooperar en la realización de una tarea, con lo cual cada individuo y miembro es responsable por el resultado absoluto beneficiando a todos los miembros del grupo. Este permite alcanzar metas gracias al trabajo en conjunto de todos sus integrantes reduciendo así la carga del trabajo individual y mejorando diferentes habilidades grupales e individuales.

El trabajo colaborativo se caracteriza por la igualdad que debe tener cada individuo en el proceso de aprendizaje, la conexión, profundidad y bidireccionalidad de la experiencia, siendo ésta una variable en función del nivel de competitividad

existente, la distribución de responsabilidades, la planificación conjunta y el intercambio de roles. [2]

La principal importancia del trabajo colaborativo se describe como: “cada participante asume su propio ritmo y potencialidades, impregnando la actividad de autonomía, pero cada uno comprende la necesidad de aportar lo mejor de sí al grupo para lograr un resultado sinérgico, al que ninguno accedería por sus propios medios; se logra así una relación de interdependencia que favorece los procesos individuales de crecimiento y desarrollo, las relaciones interpersonales y la productividad”. [3]

El trabajo colaborativo implica una cooperación que es muy útil para sus integrantes según el constructivismo social, el cual afirma que las personas activamente construyen conocimiento mientras interactúan con su ambiente ya que trabajan conjuntamente para agilizar la formación de algún tema en específico, generando una comunidad de aprendizaje dado el hecho de que se está realizando una tarea en compañía, facilitado por la interacción social, la interacción entre pares, la cooperación y la evaluación. También se debe tener en cuenta que en el trabajo colaborativo se constituyen grupos según criterios de heterogeneidad respecto tanto a características personales como de habilidades y competencias de sus miembros, lo cual propicia la complementariedad. [4]

En muchas organizaciones, la razón de su éxito es el trabajo en grupo efectivo pero generalmente los grupos que forman sin consideraciones cuidadosas (es decir, aleatoriamente) a menudo esto causa problemas tales como la participación desproporcionada de individuos, desmotivación y resistencia al trabajo en grupo en las actividades futuras.

Se debe tener en cuenta que al formar varios grupos de trabajo estos deben ser totalmente equitativos ya que de lo contrario se generara desigualdad en cuanto a rendimiento de ciertos grupos frente a otros, de esta manera afectando su avance en el tema que se esté tratando y la desigualdad de oportunidades. En otras palabras el objetivo del trabajo colaborativo es crear grupos que sean lo más similares entre sí, pero que al interior de cada uno de ellos se potencie las diferencias individuales de los integrantes que los conforman. Permitiendo así obtener logros globales que son similares entre sí.

A través del proceso de selección de las personas a participar en un grupo, se puede analizar y combinar características tales como antecedentes culturales, conocimientos, habilidades, estilos de aprendizaje, las funciones, objetivos, intereses, las calificaciones, la disponibilidad para reuniones, y así sucesivamente.

### B. Algoritmos Genéticos

La computación evolutiva reúne a todos aquellos métodos de optimización inspirados en la teoría darwiniana de la evolución de las especies. Existe una gran variedad de modelos de computación evolutiva, los cuales han sido propuestos y estudiados en las últimas décadas. Desde el punto de vista de la algoritmia, los algoritmos evolutivos son algoritmos probabilistas, es decir, toman decisiones basándose en una

distribución de probabilidad y, por tanto, el mismo algoritmo puede obtener distintos resultados para ejecuciones diferentes sobre los mismos datos. [5]

Los algoritmos evolutivos permiten encontrar buenas soluciones en tiempos razonables. La computación evolutiva se inspira en la teoría de la evolución de los seres vivos, retomando los conceptos de selección natural y genética. Estos algoritmos permiten abordar problemas complejos que surgen en las ingenierías y los campos científicos: problemas de planificación de tareas, horarios, tráfico aéreo y ferroviario, búsqueda de caminos óptimos, optimización de funciones, etc. [6]

Una debilidad de estos es que algunas veces se puede encontrar la solución de manera muy rápida en otros casos se tardan mucho en encontrarse o incluso nunca convergen en un resultado. De todos modos, tiene otro gran número de ventajas como la diversidad en su aplicación, poder trabajar sobre múltiples soluciones, la eficiencia en el cálculo de una solución objetivo y su fácil ejecución. [7]

Dentro de los algoritmos evolutivos encontramos los algoritmos genéticos los cuales tienen un esquema general con las siguientes propiedades:

- Procesan simultáneamente, trabajan representaciones de posibles soluciones al problema, denominadas individuos.
- La estructura de la población cambia a medida que pasan las iteraciones del algoritmo, denominadas generaciones.
- Para cada generación se realiza un proceso de selección según una función de aptitud, evaluando la probabilidad de que cada individuo permanezca en la población y participe en las operaciones de reproducción (cruce y mutación).

### C. Antecedentes

Expertos en el tema del trabajo colaborativo consideran que la conformación de grupos se debe hacer de forma independiente por los miembros de los mismos, lo cual no siempre produce buenos resultados. Debido a esto los estudios se centran principalmente en la interacción o correcto funcionamiento del trabajo colaborativo pero se deja a un lado la conformación de grupos para este. Sin embargo existen trabajos relacionados con el tema.

Por ejemplo FROG (FORMING REASONABLY OPTIMAL GROUPS) que es un trabajo de Investigación realizado en la Universidad de Toronto (Canadá) en el cual se plantea que existen herramientas para facilitar el proceso de conformación de grupos definiendo un modelo matemático para la formación de estos. Se muestra el proceso de implementación de un optimizador que utiliza un algoritmo evolutivo para crear grupos de acuerdo con los criterios del instructor. [8]

También se encuentra el trabajo de investigación “A Group Formation Tool for e-Learning Environments” realizado en la Universidad del Pireo (Grecia) donde se presenta una herramienta para formación de grupos basada en la web, apoyando al instructor para crear grupos homogéneos y heterogéneos basándose hasta en tres criterios para gestionar el agrupamiento. [9]



### III. PROCESO DE DESARROLLO

#### A. Modelo Propuesto

El agrupamiento de elementos es un problema combinatorio general que consiste en la repartición de un total de elementos entre un número definido de grupos, generalmente del mismo tamaño, de tal manera que se satisfaga una cierta condición. Aunque a primera vista parezca simple, la complejidad de este problema se focaliza principalmente en dos aspectos. El primero se refiere a la condición que debe ser satisfecha, la cual en el caso más común se trata de obtener grupos “equitativos” u homogéneos considerando una cierta medida de valor para cada elemento. [10]

En muchas organizaciones, los principales proyectos o trabajos se llevan a cabo en grupos de trabajo. Desafortunadamente, no existe un método claro que pueda abordar los pasos para elegir el grupo adecuado. El problema está, en este caso, en la formación óptima de grupos es la explosión combinatoria que se generaría debido al número total de individuos y los grupos a formar, siendo este el segundo aspecto a tener en cuenta. De una manera general el número posible de combinaciones que se podría obtener al desear formar  $q$  grupos, con un número total de individuos  $p$  ( $q \leq p$ ) considerando relevante el ordenamiento de los grupos está dado por la fórmula de combinatoria (1).

$$\binom{p}{q} = \frac{p!}{(p-q)!q!} \quad (1)$$

Por ejemplo al repartir 50 individuos en grupos de 5, el valor será de 2.118.760 posibles combinaciones diferentes de grupos, resaltando así que la búsqueda exhaustiva no es la mejor solución en muchos casos. En estos casos los algoritmos meta heurísticos son una buena alternativa debido a que al utilizarlos se podría llegar a una solución satisfactoria aunque no se puede garantizar el hallar una solución óptima, empleando para ello un esfuerzo de cómputo mucho menor. Entre estos algoritmos se pueden encontrar: algoritmo de recocido simulado, búsqueda local, búsqueda tabú, algoritmo de la colonia de hormigas, algoritmos genéticos, siendo este último el cual se ha seleccionado como objeto de estudio para el presente trabajo.

En el modelo propuesto como ya se ha mencionado se busca encontrar grupos similares entre sí, pero respetando la heterogeneidad de la totalidad de los miembros contrastando diferentes características como pueden ser rasgos de personalidad, calificaciones, edad, experiencia, etc.

Una vez obtenidos los datos, si existe un caso donde las características estén definidas de una forma categórica se debe discretizar numéricamente. Por ejemplo los valores “alto”, “medio” y “bajo” se podrían cambiar por 1, 2 y 3 respectivamente. Luego se deben estandarizar los valores medidos en diferentes escalas a una escala en común para que no se presenten complicaciones en el cálculo de la función objetivo. Para facilitar esto se aplica la normalización basada en la unidad mostrado en la fórmula (2).

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

Donde  $X_{\max}$  y  $X_{\min}$  son el valor máximo y mínimo de la característica correspondiente. Al obtener y organizar las características deseadas para formar los grupos se procede a conformar los grupos mediante algoritmos genéticos, primero obteniendo el promedio total para cada característica de los  $m$  miembros siendo este el objetivo a lograr, buscando que cada uno de los grupos formados se asemejen lo más posible a este promedio. Es decir, si el promedio de una característica es 0,54 entonces cada uno de los grupos formados debería acercarse a ese promedio. En la Figura 1 se muestra un ejemplo donde se tienen 6 miembros, 5 características medidas y se desean formar 3 grupos, se puede evidenciar que cada grupo generado es relativamente similar al promedio.

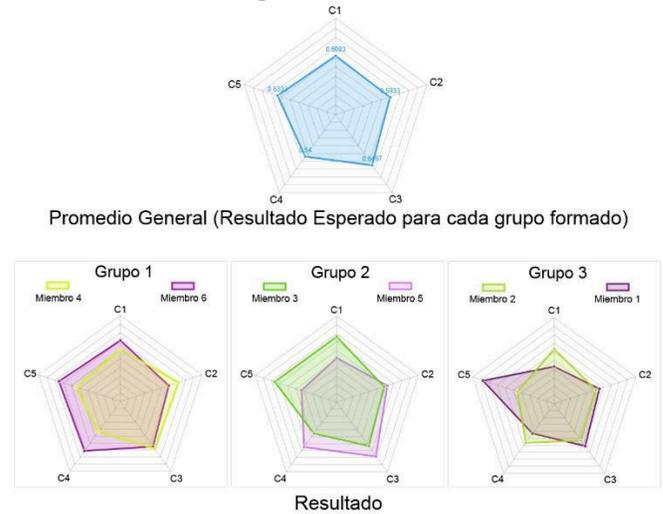


Figura 1. Resultado esperado por el algoritmo propuesto.

Lo siguiente es generar aleatoriamente una población inicial de individuos, entendiendo individuos como una posible solución al problema, teniendo en cuenta que el número de grupos a formar está dado por el número de individuos  $n$  y el número de integrantes que se desea tener en cada grupo  $g$ , así cada grupo tendrá  $n/g$  miembros sin repetición alguna. En dado caso que falten miembros para formar un grupo, se generaran miembros falsos, adoptando el promedio total de cada una de las características de la población total para que estos afecten en un bajo grado el proceso. Así por ejemplo si se desea formar grupos donde cada uno tenga 3 miembros de un total de 30 miembros, se formarían 10 grupos.

Una vez se genera la población inicial se procede a calcular el promedio de cada característica  $C$  de cada grupo  $g$  de cada individuo  $i$ , posteriormente se calcula la sumatoria de las diferencias al cuadrado del promedio de cada característica de cada grupo del individuo y el promedio calculado anteriormente para cada individuo, usando la ecuación (3).

$$D^i = \sum_{g=1}^G \left[ (\bar{C}_1 - \bar{X}_{g,1}^i)^2 + (\bar{C}_2 - \bar{X}_{g,2}^i)^2 + \dots + (\bar{C}_m - \bar{X}_{g,m}^i)^2 \right] \quad (3)$$

Entre menor sea este valor (mínimo 0) más similar serán cada uno de los grupos del individuo con respecto al promedio del total de miembros, siendo este valor de la media de aptitud.

Una vez realizado esto se puede llevar a cabo cada uno de los operados genéticos de un algoritmo genético selección, cruce y mutación, hasta que se alcance la media de aptitud deseada. En el primero se seleccionan los individuos “más aptos”, es decir con mejor media de aptitud para que luego sean clonados (bajo el principio de supervivencia del más fuerte), el segundo consiste en generar “hijos” a partir de los individuos seleccionados. Combinando los genes (miembros) de dos padres diferentes de alguna manera, teniendo en cuenta no repetir el mismo miembro en diferentes grupos. El último consiste en cambiar de manera aleatoria de uno o más cromosomas de los individuos dando paso así a una nueva generación (bajo el principio que dichos cambios pueden ser favorables). Los individuos a mutar, al igual que los cromosomas que mutan son seleccionados de manera probabilística.

El proceso continúa así hasta alcanzar la media de aptitud deseada o que pasen un número de generaciones deseadas esperando que cada vez se encuentren individuos mejores. Generalmente en trabajos donde se utilizan algoritmos genéticos, la estructura de datos que se emplea para representar un individuo es un vector donde cada posición corresponde un gen de la posible solución. En el modelo propuesto se plantea utilizar una matriz, donde el número de filas corresponde al número de grupos deseado  $g$  y el número de columnas corresponde al tamaño máximo de cada grupo  $n/g$ . Así cada gen que compone el cromosoma contiene el identificador de un miembro, y su posición dentro de la matriz define el grupo al que pertenecería. Por ejemplo, si se tiene un total de 20 miembros y se desea formar 4 grupos, cada uno tendría exactamente 5 miembros. En este caso un posible individuo, si los miembros son numerados consecutivamente, podría ser como el que se presenta en la Tabla 1.

Tabla 1. Representación de un individuo.

1	2	3	4	5
6	7	8	9	10
11	12	13	14	15
16	17	18	19	20

### B. Herramienta Desarrollada

Teniendo en cuenta lo expuesto anteriormente se realizó el desarrollo de un sistema de agrupamiento integrado en un aplicativo web modular de código abierto, esta herramienta puede ser útil para personas interesadas en desarrollar actividades colaborativas en sus espacios académicos o laborales utilizando el sistema de agrupamiento para el apoyo a la conformación de grupos de trabajo colaborativo.

Dicha aplicación ha sido nombrada como “CW-TEAMS: Software para la conformación de grupos de trabajo colaborativo basado en algoritmos genéticos” la cual se presenta como una solución informática para la administración

de grupos de trabajo colaborativo creando estos a partir de ciertas características de cada integrante, utilizando como técnica de agrupamiento y de optimización los algoritmos genéticos.

Primero se debe subir un archivo de texto con los datos necesarios para formar los grupos con un formato dado en la herramienta (Figura 2). Luego se podrá cambiar algunos parámetros como el título y descripción, así como también escoger que miembros serán los utilizados para conformar los grupos.

```

group_name=Grupo de Prueba
group_description=Grupo de Prueba del Algoritmo Genetico
characteristics_number=5
Extraversión;0;1
Cordialidad;0;1
Responsabilidad;0;1
Estabilidad emocional;0;1
Apertura a la experiencia;0;1
members_number=6
available_name=true
1;MIEMBRO 1;0.3125;0.5833;0.6389;0.375;0.675
3;MIEMBRO 3;0.5312;0.6389;0.4167;0.375;0.725
6;MIEMBRO 6;0.875;0.6389;0.6111;0.4375;0.95
2;MIEMBRO 2;0.5312;0.6944;0.5278;0.3125;0.925
4;MIEMBRO 4;0.4688;0.5556;0.6389;0.5;0.8
5;MIEMBRO 5;0.75;0.6111;0.2778;0.375;0.75

```

Figura 2. Formato de archivo de texto para subir a la herramienta.

Seguidamente se asignaran los parámetros para la ejecución del algoritmo genético como lo son el número de miembros por grupo, número de generaciones, media de aptitud, porcentaje de selección, y las probabilidades de mutación de individuos y genes (Figura 3). Luego de verificar los datos el aplicativo arrojará los resultados con un formato similar al mostrado en la Figura 1, también permitiendo visualizar el tiempo de generación y parámetros, volver a generar los resultados o descargar estos.

Subir Archivo	Miembros	Parámetros	Confirmación
Número de Miembros por Grupo		Número de Individuos	
4		80	
Número de Características		Número de Generaciones	
5		1.000	
Media de Aptitud		Porcentaje de Selección	
0,01		40%	
Probabilidad Mutación Individuos		Probabilidad Mutación Genes	
20%		15%	
Anterior		Siguiente	

Figura 3. Ventana de asignación de parámetros de la herramienta.

El código fuente de la herramienta desarrollada se encuentra en un repositorio de GitHub, donde también se encuentra un manual de usuario (<https://github.com/francoecp/cwteams>).

## IV. RESULTADOS

Para probar la eficiencia de la herramienta desarrollada y por consiguiente del algoritmo planteado se realizaron algunas pruebas con datos simulados y reales, 3 de las cuales se



presentaran a continuación, estas fueron realizadas con datos reales de estudiantes de la Universidad de donde proceden los autores, en tres diferentes asignaturas, cada estudiante realizó un test de personalidad denominado Big Five [11] el cual mide lo que muchos psicólogos consideran ser las cinco dimensiones fundamentales de personalidad para así obtener las características necesarias para la conformación de grupos, para cada uno de las asignaturas se procedió a crear el archivo necesario para cargarlo a la herramienta.

Para cada prueba se utilizó una asignatura diferente, por consiguiente y favorablemente el total de estudiantes de cada asignatura difiere, con antelación se hicieron diferentes ejecuciones del algoritmo variando sus parámetros, una vez obtenidos resultados estables estos se tomaron para su asignación en las pruebas. Las pruebas fueron realizadas en un computador con un procesador Intel Core i5 de 2,2 GHz y 8 GB de RAM. Los datos, asignaciones y resultados se muestran en la Figura 4.

No. Prueba	Asignatura	Total de estudiantes		Numero deseado de estudiantes por grupo	Total de posibles combinaciones	Numero de individuos iniciales	Numero de generaciones	Media de aptitud deseada	Porcentaje de selección (%)	Probabilidad de Mutación de cada individuo (%)	Probabilidad de mutación para los genes de cada cromosoma (grupo) (%)	Tiempo de ejecución del algoritmo (segundos)	Media de aptitud obtenida por el mejor individuo
1	Software Gráfico	24	3	2024	100	800	0,02	30	15	15	0,9704	0,0249	
2	Métodos Numéricos	48	3	17296	80	900	0,01	20	10	10	1,1343	0,0432	
3	Ingeniería de Software	22	4	7315	90	1000	0,03	40	20	20	0,6652	0,0041	

Figura 4. Resultados de las pruebas.

Analizando los datos se infiere que el proceso es muy rápido y los valores de la media de aptitud son muy cercanos al deseado. Esto demuestra la efectividad y viabilidad de la herramienta desarrollada para crear grupos equitativos, la cual utiliza un método heurístico de búsqueda que no garantiza el valor óptimo pero si un valor muy cercano a pesar de su baja demanda de recursos y tiempo de generación.

#### IV. CONCLUSIONES Y TRABAJOS FUTUROS

Considerando el problema principal, donde se desea obtener grupos homogéneos a partir de un conjunto de elementos con varios atributos, es difícil de resolver por métodos analíticos o de búsqueda exhaustiva debido a la explosión combinatoria que puede llegar a presentarse dependiendo del número de elementos y de grupos, se demuestra que una herramienta computacional es de vital importancia para la formación de estos grupos de manera rápida y eficiente.

Con los resultados que se obtuvieron gracias a las pruebas realizadas se pudo comprobar la utilidad del método

implementado en la herramienta web ya que logra obtener grupos bastante homogéneos (considerando la medida de aptitud que se escoja), incluso cuando el número de combinaciones posibles es muy elevado, sin que esto implique un elevado tiempo de cómputo.

Por otra parte, a pesar de que la formación del grupo se dice que jugar un papel crítico en términos de mejorar el éxito del trabajo colaborativo y por lo tanto aumentar el progreso de aprendizaje o de la realización de una labor, se observa que hay poca investigación que se ocupa de la formación de grupos de una manera heterogénea. [9-10] Los métodos basados en computación para ayudar en el proceso de formación de grupo no se han explorado completamente, a pesar de la popularidad de las herramientas basadas en la web para apoyar el trabajo colaborativo, los desarrolladores se centran principalmente en la interacción de colaboración para hacer frente a las técnicas de intercambio de información y recursos entre los miembros.

En el futuro, el resultado del algoritmo implementado se compara con otros algoritmos y métodos de optimización. Finalmente, se plantea incorporar en la herramienta un módulo para la gestión de cuestionarios donde primeramente se presentaran diferentes test de personalidad para obtener los datos necesarios (características) que son de utilidad para la conformación de grupos.

#### REFERENCIAS

- [1] E. E. Silva Beltrán y I. Morales Hernández, "Autonomía Y Trabajo Colaborativo", *XII Congreso Internacional De Teoría De La Educación*, 2011.
- [2] M. E. Calzadilla, Aprendizaje colaborativo y tecnologías de la información y la comunicación, *Revista Iberoamericana de Educación*, vol. 29, n. ° 1, pp. 1-10, ene. 2002.
- [3] B. C. Castro, La interrelación cognitiva entre alumno y docente, *Memorias de la Semana de Divulgación y Video Científico UJAT*, pp. 11-16, 2006.
- [4] C. L. Fraile, Hacia una comprensión del aprendizaje cooperativo. *Revista de Psicodidáctica*, pp. 59-76, 1997.
- [5] I. R. Fernandez, Aprendizaje Evolutivo De Reglas Para Agrupamiento Jerárquico De Datos En Robótica Móvil, *PhD thesis, Universidad De Santiago De Compostela*, 2016.
- [6] C. C. Lourdes Araujo, Algoritmos Evolutivos Un Enfoque Práctico, *RA-MA Editorial*, 2009.
- [7] S. G. J. M. Andrés F. Deleon, Uso de tests de aptitud y algoritmos genéticos para la conformación de grupos en ambientes colaborativos de aprendizaje, *Avances en Sistemas e Informática*, pp. 165-172, 2009.
- [8] D. H. F. P. Michelle Craig. Forming Reasonably Optimal Groups (FROG), *Proceedings of the 16th ACM international conference on Supporting group work*, pp. 141-150, 2010.
- [9] K. A. P. Christos E. Christodoulopoulos. A Group Formation Tool for e-Learning Environments, *Proceedings of IEEE Conference on Tools with Artificial Intelligence*, pp. 117-123, 2010.
- [10] J. C. R. Y. F. C. Julián Moreno, Agrupamiento Homogéneo De Elementos Con Múltiples Atributos Mediante Algoritmos Genéticos. *DYNA*, 2009.
- [11] O. E. J. Verónica Benet-Martínez. Los Cinco Grandes Across Cultures and Ethnic Groups: Multitrait Multimethod Analyses of the Big Five in Spanish and English. *Journal of Personality and Social Psychology*, pp. 729-750, 1998.

# Uso de CMSA para resolver el problema de selección de requisitos

Miguel Ángel Domínguez-Ríos  
Universidad de Málaga  
miguel.angel.dominguez.rios@uma.es

Francisco Chicano  
Universidad de Málaga  
chicano@lcc.uma.es

Enrique Alba  
Universidad de Málaga  
eat@lcc.uma.es

**Resumen**—El problema de selección de requisitos ha sido abordado en multitud de ocasiones en la literatura, tanto en su versión monoobjetivo, como biobjetivo. En su formulación usual, consiste en seleccionar un subconjunto de requisitos que se van a desarrollar en la siguiente versión de una aplicación software. Cada requisito tiene un coste y está asociado a uno o varios clientes. Para satisfacer a un cliente es necesario implementar todos los requisitos que desea. Cada cliente tiene asociado un valor para la empresa. Al resolver el problema se pretende maximizar la suma del valor de los clientes satisfechos sin superar el presupuesto de desarrollo de la siguiente versión. Existen restricciones adicionales asociadas a los requisitos que hacen el problema más complejo. Para un número elevado de variables y restricciones, los algoritmos exactos pueden resultar inviables y ser necesario recurrir a métodos heurísticos. En este trabajo proponemos el uso de la heurística *Construct, Merge, Solve and Adapt* para resolver el problema de selección de requisitos, y comparamos los resultados obtenidos con tres métodos, un algoritmo exacto y dos heurísticos, para instancias con un gran número de requisitos, clientes y dependencias.

## I. INTRODUCCIÓN

El problema de la siguiente versión (*Next Release Problem, NRP*) tiene como objetivo satisfacer las necesidades de los clientes, minimizando el esfuerzo de desarrollo de la siguiente versión de una aplicación software. Fue inicialmente propuesto por Bagnall *et al.* [2]. La idea consiste en encontrar un subconjunto de requisitos o un subconjunto de clientes que maximice una cierta propiedad, como la satisfacción de los clientes, mientras se mantiene una restricción de cota superior sobre otra propiedad, que generalmente es el coste. Hay que tener en cuenta que el NRP solo tiene en cuenta la siguiente versión software. La planificación sobre varias versiones es más compleja y se estudia dentro del *Release Planning Problem* [8], que puede considerarse como una generalización del NRP. En [13] se pueden ver aproximaciones híbridas del *Release Planning Problem*.

Recientemente, Veerapen *et al.* [14], resolvieron el problema con técnicas ILP tomando como resolutor el software de IBM, CPLEX, usando unas instancias proporcionadas por Xuan, *et al.* [16]. Éstas fueron resueltas en pocos segundos cuando años atrás era impensable, obviamente debido a las capacidades de cómputo de la actual generación de computadores y los avances en ILP. NRP es NP-duro porque el problema de la mochila se puede reducir a NRP.

Existen dos enfoques para modelar el actual NRP monoobjetivo. Por un lado, se puede exigir que todas las demandas de

los clientes sean satisfechas para poder incluir un requisito en la siguiente versión software [1], o que la satisfacción del cliente sea parcialmente aceptable [7], es decir, que se permitan satisfacer solo ciertas demandas de cierto cliente, y esto suponga también un aumento de la función objetivo. En este trabajo consideramos el primer caso, es decir, será necesario satisfacer todas las demandas del cliente, de acuerdo con la formulación general dada por Veerapen *et al.* [14].

Blum, *et al.* [3] publicaron un trabajo genérico sobre el uso de una metaheurística híbrida que resolvía problemas de optimización combinatoria. Concretamente, su trabajo es una instanciación específica dentro de un marco conocido en la literatura como *Generate-and-Solve* [9], y se conoce como *Construct, Merge, Solve & Adapt* (CMSA). La idea que proponen para resolver el problema consiste en generar una subinstancia del problema original, donde la solución óptima sea también una solución factible del problema original. La subinstancia se genera mediante la selección de ciertos componentes a tener en cuenta. Después se obtiene, mediante un resolutor exacto, una solución óptima para el subproblema. Esta solución obtenida podría estar muy alejada del verdadero óptimo. Sin embargo, los componentes que forman parte de la solución óptima del subproblema tienen un peso mayor para formar parte de la siguiente subinstancia, al menos durante un tiempo determinado. Así, se irán resolviendo subproblemas y guardando la mejor solución obtenida hasta el momento, hasta que se alcance un tiempo límite de ejecución previamente establecido. La descripción de este proceso general tiene también una fase de adaptación donde aquellos componentes que forman parte del subproblema y no han aparecido como parte de la solución óptima dentro de un número establecido de iteraciones, son desechados, lo cual no implica que puedan ser seleccionados posteriormente para formar parte de la solución. Este método híbrido, donde una heurística se mezcla con el uso de un resolutor exacto, tiene la ventaja de obtener soluciones de alta calidad (debido al uso de algoritmos exactos) a la vez que resultan rápidas, por resolver de manera exacta solo subproblemas de un tamaño reducido. La idea de resolución de instancias de un problema reducido ha sido ya explorada en varios trabajos, como por ejemplo en [4] y [10]. El método CMSA ha sido aplicado a algunos problemas, como el *Minimum Common String Partition* (MCSP) [12] o el *Minimum Covering Arborescence* (MCA) [15], entre otros, pero, hasta donde sabemos, no ha sido aplicado a NRP.



## II. FORMULACIÓN DEL NRP

Siguiendo la formulación general del NRP dada por [14], estamos interesados en maximizar el beneficio de los clientes estableciendo además un límite total de coste debido a los requisitos. Supongamos que disponemos de  $n$  posibles requisitos y  $m$  clientes. Sean  $x_1, x_2, \dots, x_n$  las variables binarias que indican la inclusión o no de cada requisito en la siguiente versión. Sean  $y_1, y_2, \dots, y_m$  las variables binarias que indican si la demanda de cada cliente ha sido completamente satisfecha o no. Sean  $c_1, c_2, \dots, c_n$  los costes asociados a los requisitos, y sean  $w_1, w_2, \dots, w_m$  los valores de beneficio asociados a los clientes. Llamemos  $b$  al límite de presupuesto para el desarrollo de la siguiente versión del software. Es posible que algunos requisitos tengan dependencias. En [17] se definieron tres posibles tipos de relaciones entre requisitos, que nosotros hemos adaptado dando nombre a cada una de ellas.

- Combinación ( $r_i \odot r_j$ ): los requisitos  $r_i$  y  $r_j$  deben aparecer juntos en cualquier selección.
- Exclusión ( $r_i \oplus r_j$ ): los requisitos  $r_i$  y  $r_j$  no pueden aparecer juntos en una selección.
- Implicación ( $r_i \Rightarrow r_j$ ): El requisito  $r_i$  requiere que el requisito  $r_j$  se incorpore en la misma selección.

El primer conjunto de dependencias indica que existen requisitos que deben aparecer (o no) conjuntamente. Cuando hay en el problema dependencias de este tipo se puede modelar el problema de manera que todas las variables con dependencia mutua sean substituidas por una nueva variable. De esta forma, la nueva variable formará parte de la solución si y solo si el conjunto de variables que dependen mutuamente forma parte de la solución. Por ello, no vamos a tener en cuenta esta situación, y consideraremos que cada variable representa a un único requisito, o directamente a un conjunto de requisitos que debe aparecer conjuntamente. El segundo conjunto de dependencias establece que pueden existir situaciones en las que dos requisitos determinados no pueden ser desarrollados conjuntamente en la siguiente versión. En este trabajo, de acuerdo con las instancias usadas por [17], tampoco vamos a considerar este tipo de restricciones. El tercer conjunto de dependencias implica que ciertos requisitos necesitan de la inclusión de otros prerequisites previos. Un requisito puede necesitar previamente de la inclusión de otro, u otros, y éstos, a su vez, de otros requisitos. En este trabajo sí vamos a considerar este tipo de dependencias.

En relación a los clientes, cada uno de ellos demanda una serie concreta de requisitos, que deben ser completamente satisfechos para poder considerar como beneficio el peso que proporciona el cliente. No se admite satisfacción parcial de un cliente en este trabajo.

Sea  $P$  el conjunto de pares  $(i, j)$  donde el requisito  $i$  es un prerequisite para el requisito  $j$ . Sea  $Q$  el conjunto de pares  $(i, k)$  donde el requisito  $i$  es demandado por el cliente  $k$ . Con todas estas consideraciones podemos modelar el NRP como un problema ILP de la siguiente manera:

$$\text{máx} \sum_{i=1}^m w_i y_i \quad (1)$$

sujeto a:

$$\sum_{i=1}^n c_i x_i \leq b \quad (2)$$

$$x_i \geq x_j \quad \forall (i, j) \in P \quad (3)$$

$$x_i \geq y_k \quad \forall (i, k) \in Q \quad (4)$$

$$x_i, y_k \in \{0, 1\} \quad \forall i = 1, \dots, n, \forall k = 1, \dots, m \quad (5)$$

## III. MÉTODO CMSA

Christian Blum *et al.* [3] establecieron un algoritmo genérico híbrido que fue usado para resolver diversos problemas combinatorios. Exponemos en el Algoritmo 1 el pseudocódigo de CMSA, que también será la base de nuestros algoritmos heurísticos, y explicamos brevemente su significado a continuación.

---

### Algoritmo 1 Construct, Merge, Solve and Adapt (CMSA)

---

- 1: **input:** instancia  $I$ , valores de los parámetros  $n_a$  y  $age_{max}$
  - 2:  $S_{bsf} = \text{NULL}$ ;  $C' = \emptyset$
  - 3:  $age[c] = 0$  para todo  $c \in C$
  - 4: **mientras** tiempo de CPU no excedido **hacer**
  - 5:   **para**  $i = 1$  hasta  $n_a$  **hacer**
  - 6:      $S = \text{ProbabilisticSolutionGenerator}(C)$
  - 7:     **para todo**  $c \in S$  y  $c \notin C'$  **hacer**
  - 8:        $age[c] = 0$  ;  $C' = C' \cup c$
  - 9:     **fin para**
  - 10:   **fin para**
  - 11:    $S'_{opt} = \text{ApplyExactSolver}(C')$
  - 12:   **si**  $S'_{opt}$  es mejor que  $S_{bsf}$  **entonces**  $S_{bsf} = S'_{opt}$
  - 13:    $\text{Adapt}(C', S'_{opt}, age_{max})$
  - 14: **fin mientras**
  - 15: **output:**  $S_{bsf}$
- 

El algoritmo parte de la suposición de que cada solución válida para una instancia  $I$  de un problema  $P$  dado, se puede representar mediante un subconjunto de un conjunto  $C$  de componentes. Este concepto de componente puede referirse a un conjunto de variables del problema, o representar algo distinto. Lo importante es que si tenemos a nuestra disposición todos los componentes para formar una solución y escogemos la mejor de ellas mediante un algoritmo exacto, resolvemos el problema original. Si solo disponemos de un subconjunto de  $C$  para formar soluciones, entonces estaremos resolviendo una subinstancia de la instancia original. El conjunto  $S \subset C$  representa una solución, no necesariamente óptima, al problema original. Por otro lado, el subconjunto  $C'$  es un contenedor que va guardando todas las componentes seleccionadas y que serán utilizadas para resolver una subinstancia de  $I$ . Por tanto, también es  $C' \subset C$ . El bucle principal se ejecuta mientras no se alcance el máximo tiempo de ejecución permitido al algoritmo. Cada iteración del algoritmo se puede dividir en cuatro partes:

1. *Construct*: se generan probabilísticamente  $n_a$  soluciones (línea 6 del Algoritmo 1).
2. *Merge*: las componentes de dichas soluciones son añadidas al contenedor  $C'$  y, a cada componente  $c$  que ha sido nuevamente añadido al contenedor, se le inicializa su edad a cero.
3. *Solve*: se resuelve la subinstancia formada por las componentes del contenedor (línea 11). Si la solución encontrada es mejor que la obtenida hasta el momento, se actualiza.
4. *Adapt*: el contenedor se adapta en base a la solución obtenida al aplicar el resolutor exacto. Cada componente de la solución óptima del subproblema reinicializa su edad a cero, y el resto de componentes aumentan su edad en una unidad. Si se supera un límite máximo de edad preestablecido,  $age_{max}$  el componente es eliminado del contenedor, aunque podrá ser incluido nuevamente en una posterior iteración.

#### IV. CMSA PARA NRP

En esta sección detallamos nuestra propuesta de adaptación de CMSA para resolver el NRP. La estructura base del programa ya está expuesta en el apartado anterior y lo único que resta por explicar es el contenido de las funciones *ProbabilisticSolutionGenerator* y *ApplyExactSolver*. En primer lugar, es necesario definir el concepto de componente para resolver una instancia del NRP. De manera natural surgen dos posibilidades: que los componentes sean los requisitos o que los componentes sean los clientes. Si los componentes son los requisitos, se seleccionará aleatoriamente un subconjunto de ellos, que no viole la restricción de coste total. Si los componentes son los clientes, se seleccionan al azar también un número determinado de ellos, pero teniendo en cuenta que las demandas de todos ellos no pueden superar el coste máximo total permitido. El procedimiento *ProbabilisticSolutionGenerator* debe generar soluciones aleatorias y de gran calidad para servir de base al resolutor exacto. Para conseguir soluciones de calidad sería deseable obtener óptimos locales, para una cierta definición de vecindario. Debemos tener en cuenta que cuando se añade un requisito a la solución parcial, es necesario añadir también todos sus prerequisites. Explicamos a continuación como gestionar el uso de la función *ProbabilisticSolutionGenerator* para cada modalidad sobre el concepto de componente y después explicamos también la gestión del uso de prerequisites.

Si consideramos que un componente está formado por un requisito, estamos interesados en generar un vector binario  $(x_1, \dots, x_n)$  que sea un máximo local. Para ello, y teniendo en cuenta de que después trataremos de maximizar el beneficio de los clientes, hemos optado por ir seleccionando requisitos que vayan saturando las demandas de los clientes, ya que una selección totalmente aleatoria de requisitos podría implicar una baja satisfacción de los clientes, y por tanto, un bajo valor objetivo. Así, iremos seleccionando aleatoriamente clientes, y añadiendo todas sus demandas mientras el coste total de los requisitos y los prerequisites asociados a estos requisitos no sobrepasen el límite establecido. Si la selección de un cliente

no satisface la condición de coste, se descarta y se pasa a otro, y este proceso se repite hasta que todos los clientes han sido analizados. En el siguiente paso, tras analizar a todos los clientes, si todavía no se ha alcanzado la cota máxima para el coste, se seleccionan de manera aleatoria más requisitos a formar parte de la solución, siempre que sea posible.

Si consideramos que un componente está formado por un cliente, estamos interesados en generar un vector binario  $(y_1, \dots, y_m)$  que sea un máximo local. Para ello procedemos de la misma forma que en el caso anterior, pero teniendo en cuenta que vamos seleccionando clientes, y no requisitos, y que no se seleccionan los requisitos finales para tratar de saturar la restricción de coste total.

Para calcular los prerequisites asociados a un requisito usamos inicialmente una estructura de datos consistente en un vector *Padre* =  $(p_1, \dots, p_n)$  donde  $p_i = i$  si el requisito no tiene ningún prerequisite asociado, y  $p_i = j$  si el requisito  $i$  tiene como prerequisite a  $j$ . De esta forma, resulta sencillo gestionar de manera recursiva el cálculo de todos los prerequisites asociados a un requisito. Sin embargo, es posible que un requisito tenga varios prerequisites asociados, por lo que el vector *Padre* pasa a convertirse en un vector donde cada elemento es una lista de elementos.

---

#### Algoritmo 2 *add-components(type)*

---

```

1:  $aux = \emptyset$ ;  $X = (0, \dots, 0)$ ;  $S = (0, \dots, 0)$ 
2: mientras queden clientes por seleccionar hacer
3:    $i \leftarrow$  elegir cliente aleatoriamente y seleccionarlo
4:    $pcost = 0$ 
5:   para cualquier requisito  $r$  no incluido previamente
6:   y demandado por  $i$  hacer
7:      $X[index(r)] = 1$ 
8:     actualizar  $pcost$ ;  $aux = aux \cup \{index(r)\}$ 
9:     para todo prerequisite  $r'$  de  $r$  no seleccionado
10:    previamente hacer
11:       $X[index(r')] = 1$ 
12:      actualizar  $pcost$ ;  $aux = aux \cup \{index(r')\}$ 
13:    fin para
14:  fin para
15:  si  $pcost \leq b$  entonces
16:     $totalcost = pcost$ ;  $S[i] = 1$ 
17:  si no
18:    para todo  $r \in aux$  hacer  $X[r] = 0$ 
19:  fin si
20: fin mientras
21: si  $type =$  requisitos entonces return (X)
22: si  $type =$  clientes entonces return (S)

```

---

En el Algoritmo 2 se muestra como se añaden los componentes a la solución parcial dependiendo de si son requisitos o clientes, y en el Algoritmo 3 se muestra la función *ProbabilisticSolutionGenerator*. El vector  $X$  es un vector binario de tamaño  $n$  que toma el valor 1 si y solo si el requisito correspondiente ha sido seleccionado. El vector  $S$  es un vector binario de tamaño  $m$  que toma el valor 1 si y solo si el cliente correspondiente es seleccionado. La variable  $pcost$  almacena




---

**Algoritmo 3** *ProbabilisticSolutionGenerator(type)*


---

```

1:  $S = \text{add-components}(type)$ 
2: si  $type = \text{requisitos}$  entonces
3:   marcar como requisito no seleccionado cualquier  $r$  tal
4:   que  $S[\text{index}(r)] = 0$ 
5:   mientras queden requisitos por seleccionar hacer
6:      $r \leftarrow$  elegir requisito aleatoriamente y seleccionarlo
7:      $r' \leftarrow$  seleccionar prerrequisitos de  $r$  no seleccionados
8:     previamente
9:     si el coste añadido no supera el límite entonces
10:       $S[r] = 1$ 
11:       $S[r^*] = 1$  para todo  $r^* \in r'$ 
12:      actualizar  $totalcost$ 
13:     fin si
14:   fin mientras
15: fin si
16: return ( $S$ )

```

---

el coste parcial que será añadido, en su caso, a la variable  $totalcost$  que almacena el coste total acumulado y que nunca debe ser mayor que  $b$ . El conjunto  $aux$  guarda los índices de los requisitos y prerrequisitos seleccionados para formar parte de la solución. Si se viola la restricción de coste máximo, gracias al conjunto  $aux$  es posible restaurar el vector  $X$ .

A continuación explicamos la función *ApplyExactSolver*. Suponemos que disponemos de un resolutor que resuelve problemas ILP. De una manera muy sencilla podemos adaptar el contenido de esta función sin más que añadir una restricción al modelo, aquella que no tiene en cuenta los requisitos que no están en el contenedor o los clientes que no están en el contenedor, según el caso. El pseudocódigo de esta función puede verse en el Algoritmo 4.

---

**Algoritmo 4** *ApplyExactSolver ( $C'$ )*


---

```

1: añadir restricción  $\sum_i x_i = 0$  para todo  $x \notin C'$  al
   problema original
2:  $S'_{opt} \leftarrow$  obtener solución de la subinstancia
3: borrar la restricción añadida previamente
4: return ( $S'_{opt}$ )

```

---

## V. RESULTADOS COMPUTACIONALES

En esta sección mostramos los resultados computacionales para ciertas instancias del NRP que han sido generadas aleatoriamente. Dado que las instancias dadas por Xuan *et al.* [16] ya han sido resueltas de manera exacta en pocos segundos, no tiene sentido aplicar la heurística CMSA en este caso. Para ello, hemos creado instancias aleatorias con un número muy elevado de requisitos, clientes y dependencias, para poder así comprobar los resultados en relación a lo que proporciona la heurística CMSA en sus dos variantes (siendo los componentes requisitos o clientes) y la que proporciona el propio resolutor cuando resolvemos el problema exacto durante un tiempo fijado.

Las instancias aleatorias han sido creadas teniendo en cuenta que no se produzcan bucles en la lectura de los prerrequisitos, lo cual se ha logrado usando estructuras *Union-Find* [5, cap. 21]. Los parámetros de las instancias generadas aleatoriamente son los siguientes: Se determinan  $n$  requisitos,  $m$  clientes y  $k$  dependencias entre requisitos. Los costes de los requisitos son números aleatorios enteros entre 1 y 10. Los pesos de los clientes son números aleatorios enteros entre 1 y 100. Cada cliente demanda un número aleatorio de requisitos que varía entre 1 y 8. Se han generado seis grupos de instancias, con los prefijos desde  $a$  hasta  $e$ . Para nombrar una instancia, se indica el nombre del grupo y los valores  $n$ ,  $m$ , y  $k$ , separados por guiones entre ellos. Cada grupo representa una relación distinta entre los parámetros variables  $n$ ,  $m$  y  $k$ . Así, se han considerado casos en que  $n$  puede ser mayor que  $m$  (grupos a y c), mucho mayor (grupos b y d) o similar (grupos e y f), al igual que  $m$  puede ser mayor que  $k$  (grupos a, b ó e) o similar (grupos (c, d ó f)). Como límite total de coste para los requisitos se suele utilizar un coeficiente reductor sobre la suma total de los costes de todos los requisitos. En nuestro caso hemos optado por usar dos valores para este coeficiente: 0.3 y 0.7. El tiempo de ejecución máximo ha sido fijado en 60 segundos. Como resolutor hemos usado CPLEX 12.6.2.

Los experimentos han sido ejecutados bajo entorno Linux (Ubuntu 16.04 LTS) en un máquina HP con Intel Core 2 Quad (Q9400), velocidad de procesador 2.7 GHz y 4 GB de RAM, usando un máximo de 2GB de RAM y un único núcleo.

Los tres métodos usados, cuyos resultados serán comparados entre ellos son:

1. Algoritmo exacto usando el problema original y estableciendo tiempo límite de ejecución (*exact*)
2. Algoritmo CMSA utilizando los requisitos como componentes ( $cmsa_r$ ) y parámetros  $n_a = 5$ ,  $age_{max} = 2$
3. Algoritmo CMSA utilizando los clientes como componentes ( $cmsa_s$ ) y parámetros  $n_a = 5$ ,  $age_{max} = 2$

En el caso del algoritmo exacto se ha ejecutado 10 veces cada instancia, ya que la calidad de los resultados de CPLEX pueden variar en distintas ejecuciones debido a la diferente carga de la máquina. Las variantes de CMSA se han ejecutado 30 veces para cada instancia, un número considerablemente mayor dado el componente aleatorio de la heurística. En todos los casos se utiliza el valor promedio dado por las funciones objetivo. Los resultados para los distintos coeficientes reductores pueden verse en los Cuadros I y II. Las instancias marcadas con asterisco en la primera columna de los Cuadros I y II, son aquellas en las que el algoritmo exacto obtiene el óptimo global.

El análisis de los resultados para el coeficiente 0.3 del cuadro I muestra una variedad en cuanto a los resultados. Se ha marcado en negrita el mejor resultado para cada una de las instancias, teniendo en cuenta los valores promedio. Puede observarse que para aquellas instancias en las que el algoritmo exacto es mejor, el valor objetivo proporcionado por las heurísticas no es muy distante. Sin embargo, en aquellas instancias en las que la heurística es mejor, la diferencia en relación a la solución obtenida por el algoritmo exacto es,

Cuadro I

 VALORES OBJETIVO PROMEDIO PARA LOS TRES MÉTODOS PROPUESTOS,  
 USANDO INSTANCIAS GENERADAS ALEATORIAMENTE DURANTE 60  
 SEGUNDOS Y CON PRESUPUESTO  $b = 0.3 \sum_{i=1}^n c_i$ .

instancia	<i>exact</i>	<i>cmsa_r</i>	<i>cmsa_s</i>
a20000-15000-4000	146018.0	<b>263387.1</b>	253287.2
a40000-30000-8000	287108.0	337520.6	<b>479641.2</b>
a80000-60000-16000	<b>562858.0</b>	506890.8	558241.5
a120000-90000-24000	<b>866539.0</b>	777432.0	852102.8
b20000-15000-15000	89272.0	103588.9	<b>178089.7</b>
b40000-30000-30000	166559.0	134943.8	<b>323032.7</b>
b80000-60000-60000	<b>340646.0</b>	276249.3	291939.1
b120000-90000-90000	360537.8	418888.4	<b>443369.2</b>
c20000-5000-4000*	<b>168572.0</b>	<b>168572.0</b>	<b>168572.0</b>
c40000-10000-8000*	<b>329473.0</b>	326309.9	325006.1
c80000-20000-16000	290985.0	301780.0	<b>371700.9</b>
c120000-30000-24000	449524.0	449683.2	<b>458293.3</b>
d20000-5000-5000*	<b>161697.0</b>	161696.7	<b>161697.0</b>
d40000-10000-10000*	<b>322819.0</b>	315514.8	313263.4
d80000-20000-20000	269804.0	281128.0	<b>295590.2</b>
d120000-30000-30000	391402.0	392500.8	<b>398782.4</b>
e20000-18000-4000	175321.0	<b>290948.8</b>	269240.6
e40000-36000-8000	355931.0	494322.9	<b>525250.4</b>
e80000-76000-16000	<b>770482.0</b>	654382.5	707105.5
e120000-108000-24000	<b>1078305.9</b>	926170.8	1004343.5
f20000-18000-18000	87259.0	107617.3	<b>199510.7</b>
f40000-36000-36000	177267.0	146402.7	<b>319233.9</b>
f80000-75000-75000	<b>361914.0</b>	295269.3	315160.4
f120000-108000-108000	-	435019.0	<b>459930.6</b>

Cuadro II

 VALORES OBJETIVO PROMEDIO PARA LOS TRES MÉTODOS PROPUESTOS,  
 USANDO INSTANCIAS GENERADAS ALEATORIAMENTE DURANTE 60  
 SEGUNDOS Y CON PRESUPUESTO  $b = 0.7 \sum_{i=1}^n c_i$ .

instancia	<i>exact</i>	<i>cmsa_r</i>	<i>cmsa_s</i>
a20000-15000-4000	420936.0	417669.1	<b>438157.3</b>
a40000-30000-8000	856336.0	867279.3	<b>888971.7</b>
a80000-60000-16000	562858.0	557780.3	<b>564892.4</b>
a120000-90000-24000	866539.0	858235.1	<b>869302.4</b>
b20000-15000-15000	325142.0	330771.0	<b>343229.2</b>
b40000-30000-30000	650947.5	664219.9	<b>677113.9</b>
b80000-60000-60000	<b>1237348.0</b>	1164320.8	1220072.4
b120000-90000-90000	463548.6	438897.5	<b>733116.3</b>
c20000-5000-4000*	<b>249727.0</b>	<b>249727.0</b>	<b>249727.0</b>
c40000-10000-8000*	<b>492957.0</b>	<b>492957.0</b>	<b>492957.0</b>
c80000-20000-16000*	<b>993343.0</b>	<b>993343.0</b>	<b>993343.0</b>
c120000-30000-24000*	<b>1484724.0</b>	<b>1484724.0</b>	<b>1484724.0</b>
d20000-5000-5000*	<b>244459.0</b>	<b>244459.0</b>	<b>244459.0</b>
d40000-10000-10000*	<b>493255.0</b>	<b>493255.0</b>	<b>493255.0</b>
d80000-20000-20000*	<b>993806.0</b>	<b>993806.0</b>	<b>993806.0</b>
d120000-30000-30000*	<b>1485762.0</b>	<b>1485762.0</b>	<b>1485762.0</b>
e20000-18000-4000	433501.0	438125.7	<b>458748.1</b>
e40000-36000-8000	877810.0	887865.9	<b>924538.8</b>
e80000-76000-16000	770482.0	760625.6	<b>773035.3</b>
e120000-108000-24000	1077713.5	888231.8	<b>1082415.2</b>
f20000-18000-18000	87259.0	<b>352584.9</b>	319687.6
f40000-36000-36000	177267.0	704608.2	<b>719070.1</b>
f80000-75000-75000	<b>1383684.0</b>	1283686.5	1099710.2
f120000-108000-108000	-	-	<b>158342.4</b>

en ocasiones, muy elevada, como por ejemplo en la instancia *b120000-90000-90000*, donde *cmsa\_s* proporciona un objetivo en torno al 67 % mejor que el algoritmo exacto. Esto justifica la utilidad del uso de estos nuevos algoritmos. También aparecen instancias en las que los resultados obtenidos por los tres métodos son iguales, como en el caso de *c20000-5000-4000*. Obsérvese también que en la instancia *f120000-108000-108000*, al tener gran cantidad de requisitos, clientes y dependencias, CPLEX es incapaz de encontrar ninguna solución durante el primer minuto de ejecución. Se conjetura que en torno a esos valores elevados de requisitos y clientes empieza a observarse un umbral a partir del cual parece ser más productivo el uso de la heurística CMSA en favor del uso de algoritmos exactos. Si comparamos *cmsa\_r* con *cmsa\_s*, podemos comprobar que en la mayoría de los casos *cmsa\_s* proporciona unos resultados mejores, lo que nos permite deducir la importancia de elegir una buena definición de componente en el uso de la heurística CMSA, ya que los resultados para una misma instancia pueden variar considerablemente si cambiamos dicha definición.

Analizando ahora el Cuadro II para las mismas instancias de antes, pero aumentado el coeficiente reductor a 0.7, realizando el mismo número de ejecuciones que en el caso anterior, y calculando promedios, se observa como los resultados varían considerablemente. Para los grupos de instancias *c* y *d* los objetivos obtenidos son iguales para los tres casos (la solución óptima), por lo que no se detecta ninguna diferencia en el uso de los tres algoritmos. Sin embargo, para la mayoría de las restantes instancias, es claramente *cmsa\_s* el método con el que se obtienen mejores resultados. Si suprimimos los grupos en el que los resultados son iguales, el método exacto solo es mejor en dos casos, mientras que *cmsa\_r* solo lo es en un caso. Además, para la instancia *f120000-108000-108000*, ni el algoritmo exacto, ni *cmsa\_r* consiguen encontrar una solución factible dentro del primer minuto de ejecución. Este hecho resalta nuevamente la importancia de una buena elección de componentes, que en este caso parece ser favorable a *cmsa\_s*.

## VI. CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN

Tras los resultados obtenidos con el uso de CMSA para resolver el NRP en instancias aleatorias con gran número de requisitos, clientes y dependencias, se puede conjeturar que el uso de la heurística *cmsa\_s* es la más adecuada para resolver instancias grandes de NRP. Todos los experimentos se han realizado fijando los parámetros  $n_a = 5$  y  $age_{max} = 2$ , aunque podrían haberse obtenido resultados diferentes (posiblemente mejores) para otra configuración de estos parámetros. Tras realizar el test de Wilcoxon con datos apareados a cada pareja de algoritmos y en cada una de las modalidades, los resultados de los cuadros III y IV muestran que existen diferencias significativas en cuanto al comportamiento del algoritmo *cmsa\_s* respecto a los otros dos (al nivel de significancia del 5 %). Realizando nuevamente los tests pero estableciendo como hipótesis alternativa que *cmsa\_s* es mejor, se obtienen los resultados que se muestran en el cuadro V. Acorde a [6]



el número de algoritmos usados para la comparación, que es tan solo de tres, no recomienda el uso del test de Friedman. En conclusión, podemos garantizar estadísticamente que, con estas instancias, el algoritmo *cmsa\_s* es el mejor de los tres algoritmos analizados.

Una línea futura de investigación sobre este trabajo podría ser aplicar el paquete *iRace* [11], que permitiría obtener una configuración óptima de dichos parámetros dentro de un rango preestablecido. También se podría estudiar más a fondo el problema, con un rango más amplio de requisitos, clientes y dependencias, y estimar a partir de qué valores de estos parámetros se obtienen mejores resultados para un método u otro. Esto se podría conseguir también usando el paquete *iRace* y se matizaría en un algoritmo mediante combinación de los anteriores que sirviese como método híbrido que determina cuál es el mejor método a utilizar en función de los parámetros de entrada.

Cuadro III

TEST DE WILCOXON (DATOS APAREADOS) PARA CONTRASTAR SI HAY DIFERENCIA ENTRE LOS ALGORITMOS PROPUESTOS,  $b = 0,3 \sum_{i=1}^n c_i$

	<i>exact</i>	<i>cmsa_r</i>
<i>cmsa_r</i>	0.89110	-
<i>cmsa_s</i>	0.01629	0.00040

Cuadro IV

TEST DE WILCOXON (DATOS APAREADOS) PARA CONTRASTAR SI HAY DIFERENCIA ENTRE LOS ALGORITMOS PROPUESTOS,  $b = 0,7 \sum_{i=1}^n c_i$

	<i>exact</i>	<i>cmsa_r</i>
<i>cmsa_r</i>	0.97730	-
<i>cmsa_s</i>	0.01620	0.02449

Cuadro V

CONTRASTES UNILATERALES CON HIPÓTESIS ALTERNATIVA  
 $H_1 : cmsa_s > col$ , SIENDO  $col \in \{exact, cmsa_r\}$

	<i>exact</i>	<i>cmsa_r</i>
$b = 0,3 \sum_{i=1}^n c_i$	0.00814	0.00020
$b = 0,7 \sum_{i=1}^n c_i$	0.00810	0.01225

También es posible generalizar el método CMSA para el caso multiobjetivo y aplicarlo inicialmente al NRP biobjetivo. De hecho, hemos trabajado en esta posibilidad, pero no hemos obtenido unos resultados iniciales satisfactorios, debido principalmente a dos problemas. El primero es que la elección de componentes como aquellos entes más válidos a formar parte de una solución, no viene a ser una tarea fácil para un problema biobjetivo, donde el espacio de soluciones es bidimensional y el comportamiento de las variables de decisión puede variar considerablemente para distintas zonas del espacio objetivo. El segundo problema encontrado es la forma de aplicar la función *ExactSolver* para el caso biobjetivo, ya que un barrido completo por el espacio objetivo en cada iteración, no solo consume demasiado tiempo de ejecución, sino que además las soluciones obtenidas suelen estar muy lejos de los valores óptimos, por lo que el prototipo de CMSA biobjetivo resulta

poco eficaz. Hemos pensado en la posibilidad de subdividir el espacio objetivo en varias zonas y aplicar CMSA a cada una de ellas. Seguimos trabajando en este sentido.

## VII. AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad (proyectos TIN2014-57341-R y TIN2017-88213-R) y por la Universidad de Málaga.

## REFERENCIAS

- [1] Philip Achimugu, Ali Selamat, Roliana Ibrahim, and Mohd Naz'ri Mahrin, *A systematic literature review of software requirements prioritization research*, Inform. and software technology **56** (2014), no. 6, 568–585.
- [2] Anthony J. Bagnall, Victor J. Rayward-Smith, and Ian M Whittle, *The next release problem*, Information and software technology **43** (2001), no. 14, 883–890.
- [3] Christian Blum, Pedro Pinacho, Manuel López-Ibáñez, and José A Lozano, *Construct, merge, solve & adapt a new general algorithm for combinatorial optimization*, Computers & Operations Research **68** (2016), 75–88.
- [4] W. Cook and P. Seymour, *Tour merging via branch-decomposition*, INFORMS Journal on Computing **15** (2003), no. 3, 233–248.
- [5] Thomas H Cormen, Charles E Leiserson, Ronald L Rivest, and Clifford Stein, *Introduction to algorithms*, MIT press, 2009.
- [6] Joaquín Derrac, Salvador García, Daniel Molina, and Francisco Herrera, *A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms*, Swarm and Evolutionary Computation **1** (2011), no. 1, 3–18.
- [7] J.J. Durillo, Y. Zhang, E. Alba, and Antonio J Nebro, *A study of the multi-objective next release problem*, Search Based Software Engineering, 2009 1st International Symposium on, IEEE, 2009, pp. 49–58.
- [8] Des Greer and Guenther Ruhe, *Software release planning: an evolutionary and iterative approach*, Information and software technology **46** (2004), no. 4, 243–253.
- [9] Janusz Kacprzyk, *Studies in computational intelligence, volume 153*, (2008).
- [10] Gunnar W Klau, Ivana Ljubić, Andreas Moser, Petra Mutzel, Philipp Neuner, Ulrich Pferschy, Günther Raidl, and René Weiskircher, *Combining a memetic algorithm with integer programming to solve the prize-collecting steiner tree problem*, Genetic and Evolutionary Computation Conference, Springer, 2004, pp. 1304–1315.
- [11] Manuel López-Ibáñez, Jérémie Dubois-Lacoste, Leslie Pérez Cáceres, Mauro Birattari, and Thomas Stützle, *The irace package: Iterated racing for automatic algorithm configuration*, Operations Research Perspectives **3** (2016), 43–58.
- [12] Claudio N Meneses, Carlos AS Oliveira, and Panos M Pardalos, *Optimization techniques for string selection and comparison problems in genomics*, IEEE Engineering in Medicine and Biology Magazine **24** (2005), no. 3, 81–87.
- [13] Günther Ruhe and Moshood Omolade Saliu, *The art and science of software release planning*, IEEE Software **22** (2005), 47–53.
- [14] Nadarajen Veerapen, Gabriela Ochoa, Mark Harman, and Edmund K Burke, *An integer linear programming approach to the single and bi-objective next release problem*, Information and Software Technology **65** (2015), 1–13.
- [15] V Venkata Rao, R Sridharan, et al., *The minimum weight rooted arborescence problem: weights on arcs case*, Tech. report, Indian Institute of Management Ahmedabad, Research and Publication Department, 1992.
- [16] Jifeng Xuan, He Jiang, Zhilei Ren, and Zhongxuan Luo, *Solving the large scale next release problem with a backbone-based multilevel algorithm*, IEEE Transactions on Software Engineering **38** (2012), no. 5, 1195–1212.
- [17] Yuanyuan Zhang, Mark Harman, and S Afshin Mansouri, *The multi-objective next release problem*, Proceedings of the 9th annual conference on Genetic and evolutionary computation, ACM, 2007, pp. 1129–1137.



# A First Step to Accelerating Fingerprint Matching based on Deformable Minutiae Clustering\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

A.J. Sanchez

*Dpt. of Computer Architecture  
University of Málaga  
Málaga, Spain  
ajsanchez@ac.uma.es*

L.F. Romero

*Dpt. of Computer Architecture  
University of Málaga  
Málaga, Spain  
felipe@uma.es*

S. Tabik

*Dpt. Computer Science and Artificial Intelligence  
University of Granada  
Granada, Spain  
siham@ugr.es*

M.A. Medina-Pérez

*Tecnológico de Monterrey  
México  
migue@itesm.mx*

F. Herrera

*Dpt. Computer Science and Artificial Intelligence  
University of Granada  
Granada, Spain  
herrera@decsai.ugr.es*

**Abstract**—Fingerprint recognition is one of the most used biometric methods for authentication. The identification of a query fingerprint requires matching its minutiae against every minutiae of all the fingerprints of the database. The state-of-the-art matching algorithms are costly, from a computational point of view, and inefficient on large datasets. In this work, we include faster methods to accelerating DMC (the most accurate fingerprint matching algorithm based only on minutiae). In particular, we translate into C++ the functions of the algorithm which represent the most costly tasks of the code; we create a library with the new code and we link the library to the original C# code using a CLR Class Library project by means of a C++/CLI Wrapper. Our solution re-implements critical functions, e.g., the bit population count including a fast C++ PopCount library and the use of the squared Euclidean distance for calculating the minutiae neighborhood. The experimental results show a significant reduction of the execution time in the optimized functions of the matching algorithm. Finally, a novel approach to improve the matching algorithm, considering cache memory blocking and parallel data processing, is presented as future work.

**Index Terms**—Fingerprint Recognition, Cache Optimization, Language Interoperability



# Running Genetic Algorithms in the Edge: A First Analysis\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

José Á. Morell, Enrique Alba

*Departamento de Lenguajes y Ciencias de la Computación*

*Universidad de Málaga*

Málaga, Spain

{jmorell, eat}@lcc.uma.es

**Abstract**—Nowadays, the volume of data produced by different kinds of devices is continuously growing, making even more difficult to solve the many optimization problems that impact directly on our living quality. For instance, Cisco projected that by 2019 the volume of data will reach 507.5 zettabytes per year, and the cloud traffic will quadruple. This is not sustainable in the long term, so it is a need to move part of the intelligence from the cloud to a highly decentralized computing model. Considering this, we propose a ubiquitous intelligent system which is composed by different kinds of endpoint devices such as smartphones, tablets, routers, wearables, and any other CPU powered device. We want to use this to solve tasks useful for smart cities. In this paper, we analyze if these devices are suitable for this purpose and how we have to adapt the optimization algorithms to be efficient using heterogeneous hardware. To do this, we perform a set of experiments in which we measure the speed, memory usage, and battery consumption of these devices for a set of binary and combinatorial problems. Our conclusions reveal the strong and weak features of each device to run future algorithms in the border of the cyber-physical system.

**Index Terms**—Edge Computing, Fog Computing, Evolutionary Algorithms, Genetic Algorithms, Metaheuristics, Smartphone, Tablet, Ubiquitous AI



**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 5:  
INTELIGENCIA ARTIFICIAL:  
DATOS ABIERTOS,  
PROBLEMAS Y FUNDAMENTOS







# GraphDL: An Ontology for Linked Data Visualization\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Juan Gómez-Romero  
*Dep. of Computer Science and Artificial Intelligence*  
*University of Granada*  
Granada, Spain  
jgomez@decsai.ugr.es

Miguel Molina-Solana  
*Data Science Institute*  
*Imperial College London*  
London, United Kingdom  
m.molina-solana@imperial.ac.uk

**Abstract**—Linked Data is an increasingly important source of information and contextual knowledge in Data Science, and its appropriate visualization is key to effectively exploit them. This work presents an ontology to generate graph-based visualizations of Linked Data in a flexible and efficient way. The ontology has been used to successfully visualize DrugBank and DBPedia datasets in a large visualization environment.

**Index Terms**—Linked Data, Ontologies, Visualization, Big Data

# Aragon Open Data: A NLP-Based ontology population for Public Administration

Paula Peña

*Big Data and Cognitive Systems*  
*Technological Institute of Aragon (ITAINNOVA)*  
Zaragoza, Spain  
ppena@itainnova.es

Rocío Aznar

*Big Data and Cognitive Systems*  
*Technological Institute of Aragon (ITAINNOVA)*  
Zaragoza, Spain  
raznar@itainnova.es

Rafael del Hoyo

*Big Data and Cognitive Systems*  
*Technological Institute of Aragon (ITAINNOVA)*  
Zaragoza, Spain  
rdelhoyo@itainnova.es

Rosa Montañés

*Big Data and Cognitive Systems*  
*Technological Institute of Aragon (ITAINNOVA)*  
Zaragoza, Spain  
rmontanes@itainnova.es

**Abstract**—Governments are one of the main producers of information and initiatives of making government open data are continuously gaining interest, recently. In this sense, how to provide relevant elements to improve the structuring of institutional information and deepen its standardization to make easier its access and make use of the information has become an important challenge and allows a great value to initiatives that leverage the potential of Open Data. Within this context, given the amount of unstructured information related to the Government of Aragon published on Internet at this time, with slightly or no standardization and decentralized, the need to gather it systematically to be served from a single access point in a public and structure way emerges. In this paper, an approach based on the use of web crawling, Natural Language Processing and ontology-based techniques is proposed. Experimental results based on disperse, non-homogeneous, uncontrolled and non-exploitable institutional information validate that the proposed approach improves the structuring and standardization of data that can be analyzed together, be accessible, be browsed, be exploited and offered to all interested collectives. The generated ontology is populated with institutional data, affording and securing new possibilities of generating valuable and consistent ontology-based knowledge services.

**Index Terms**—Open Data, Ontologies, Natural Language Processing

## I. INTRODUCTION

Open Data is now a worldwide movement whose philosophy aims to provide data openness and availability to citizens. Many countries have an Open Data initiative<sup>1</sup>. Even in countries where that data is not yet fully open, civil society and the technology community are using government data. In Europe, Open Data has been a focus for policymakers for over a decade<sup>2</sup>. Today, almost all European countries have an Open Data portal, and these portals are becoming more advanced, being used more frequently and creating more benefits for

<sup>1</sup>Barometer Global Report, <https://opendatabarometer.org>, last accessed 2018/05/25

<sup>2</sup>The Re-use of Public Sector Information Regulations, <http://www.legislation.gov.uk/uksi/2015/1415/made>, last accessed 2018/09/10

citizens. As part of a national Open Data initiative, regional and provincial governments and by councils at city level have not been unresponsive to these initiatives.

Aragon Open Data is a project to open data by agreement of July 17, 2012 of the Government of Aragon, and its Internet portal<sup>3</sup> was presented with the objectives of creating economic within the ICT sector through the reuse of public information, increasing transparency in the Administration, promoting innovation, improving information systems of the Administration, adopting technical standards in the information society field and generating data interoperability between public sector websites. Throughout this time, there have been numerous works that allow the incorporation of new data and information available to third parties (citizens, companies, infomediary sector, developers, etc.).

In this context, on one hand, given the volume of the data that begins to exist in the Aragonese public administration, are beginning to have a special relevance all tools that help in the improvement of the structuring the information and in the standardization of data. The idea of generating a set of technical and legal rules that allow deepening in that standardization arises. On the other hand, within the line of difficulty of access and use of information, the complex casuistry presented by the regional public administration in the generation of data and information is reflected in the proliferation of a large number of websites under its root domain: `aragon.es`. These circumstances make it difficult to access and make use of information by third parties as well as public administration services of Aragon, generating the popular sense of certain lack of transparency.

This work introduces an approach to allow institutional information that is in a dispersed, non-homogeneous, non-controlled and non-exploitable way become into structured data that can be analyzed, accessible, reused, browsed, ex-

<sup>3</sup>Aragon Open Data, <http://opendata.aragon.es>, last accessed 2018/09/10



exploited and served in a controlled mode under a single point. A semantic ontology has been designed and created to structure and standardize public administration information. This ontology, known as *Interoperable Information Scheme of Aragon (EI2A)*, allows modeling organizational structures, natural persons, places, territories, temporal properties of resources, events, websites, etc. In addition, a prototype has been implemented to recover open data related to the organizational chart of the Government of Aragon and all the information offered on institutional web to structure it according to EI2A ontology. Information conversion into knowledge and useful data is performed through the application of techniques and technologies such as *web crawling* or *spider*, intelligent data processing, Natural Language Processing (NLP), semantic technologies for the representation of knowledge and Big Data architecture. Specifically, the approach exploits text processing and automatic population technologies to extract knowledge from institutional content and organize it conceptually in EI2A ontology.

This paper is organized as follows: Related work on the use of semantic and NLP techniques to extract knowledge and structure it is presented in Section 2. Section 3 describes the architecture used and presents a high level description of proposed approach. EI2A ontology used is described in section 4. We discuss results in section 5 and highlight implications and of the work made. Finally, section 6 describes conclusions and discusses ideas for future work.

## II. RELATED WORK

Initiatives of making government open data are continuously gaining interest, recently. While more countries are embracing the Open Government paradigm, among the researchers working with those data there is an increasing awareness in using semantic techniques to represent them. Applying semantic web technologies enables data integration among different organization and established links to interconnect data on the Web [1]. Integration of raw data gathered from different sources, and formally and semantically represented and based on ontology, leads to opportunities for information exchange, analysis on combined datasets, simplicity in creation of mash-ups, and exploration of innovative ways to use data creatively. Enhancing with application of semantic web technologies to link data, and provide unexpected and unexplored insights into different domains and problem areas is the real value of open government data [2].

Application of semantic web technologies in government not only contributes to opening data to the community but also contributes to creating a knowledge network map that interconnects different sources that actually share data [3]. By making government data discoverable and accessible to the public, government shows that they are dedicated to the application of innovative e-services to improve accessibility, reusability and easy consumption of their data [4]. This leads to extends characteristics of publicly available data [5]. On the other hand, ontologies have become a major tool for developing semantically rich application. They provide for

a standardized means of modeling, querying, and reasoning over large knowledge bases. Specialized knowledge services require tools such as [6] that can search and extract specific knowledge directly from unstructured text on the Web, guided by ontology. Other researchers have used ontology to support knowledge extraction [7], [8].

In a world in which the majority of knowledge is encoded in natural language text, automating the population of these ontologies using results obtained from the application of NLP techniques is becoming increasingly important and a major challenge [9]. The process of automatic or semi-automatic construction, enrichment, population and adaptation of ontologies is known as ontology learning. Ontology population is the task of adding new instances of concepts. Different approaches exit to export or populate results of NLP analyses into ontology such as [10], [11]. In addition, NLP techniques for term extraction and ontology population, using a combination of rule-based approaches and machine learning is described in [12]. In [13] links a knowledge-extraction tool with ontology to achieve continuous knowledge support and guide information extraction.

This paper aims to focus on the new possibilities afforded by semantic web and natural language technologies in the area of knowledge management and open government data to allow institutional information from very diverse, scattered and different sources to be structured formally and semantically to facilitate its analysis, accessibility, reuse and exploitation from a single access point in a public way.

## III. PROPOSED APPROACH

The high-level architecture of the proposed approach (see Fig. 1) is primarily focused on information retrieval. Particularly, textual information of websites under *aragon.es* domain using *web crawling*, *spidering* or *spider* techniques and data related to the organizational chart of the Government of Aragon are retrieved. Secondly, the extracted textual information is analyzed/processed using NLP techniques for lowercase conversion, lemmatization, stopwords filtering, the dictionaries application, cleaning tasks, recognition and classification of concepts and summarization. Lastly, results are stored into NoSQL databases that allow the indexation of rich text and structuring information according to the EI2A ontology for later consultation through the Aragon Open Data access point.

To implement the functionalities of the proposed approach, a set of sub-processes has been developed through an own framework called *Moriarty*<sup>4</sup> [14]. *Moriarty* is an advanced Artificial Intelligence software solution framework for Big Data, developed by ITAINNOVA<sup>5</sup>. It is based on two basic concepts: *workitem* (class that implements an atomic function, and that can be used in multiple contexts reuse concept) and *workflow* (composed of workitems or other workflows that receive some inputs and perform transformations in them generating and returning some outputs).

<sup>4</sup>Moriarty, <http://www.ita.es/moriarty>, last accessed 2018/09/10

<sup>5</sup>Instituto Tecnológico de Aragón, <http://www.itainnova.es>, last accessed 2018/09/10



Fig. 1. High-level architecture.

Through the execution of a periodic process, open data related to the Government of Aragon organizational chart (legislatures, entities, roles) are accessed in reusable formats (*xml*, *csv*, *json*) from Aragon Open Data portal with the aim of structuring them according to the EI2A ontology. It is initially populated with this data and is available as RDF (*Resource Description Framework*). Since web information could change regularly and new web pages may appear, a web crawling process is executed periodically (see Fig. 2), analyzing the new webs that emerge or reprocessing the webs that have changed, and thus to have the information updated. URL information of websites in an updated *csv* file is considered as the seed of this approach. *ExtractURLsFile* sub-process extracts them in order to analyze and process them. Initialized the necessary variables to carry out the entire web crawling process in *CsvToText* sub-process, a list of URLs filtered to avoid images, *css* or unauthorized links is created with the depth of analysis, the maximum number of pages to analyze and the number of crawling-threads desired in *Crawling* workitem. It uses *crawler4j*<sup>6</sup> library, presented as the most suitable available for the recovery of institutional information offered in websites, after a thorough analysis of the current state on research trends and technological development in relation to web crawling techniques and after developing and following a methodology with the objective of applying selection criteria.

With the aim of granting a unique identifier to the new pages instances to be processed and analyzed, *GetMaxURLID*

sub-process returns the maximum identifier inserted in *Openlink Virtuoso* database. *Url-to-url*, *ExtractTextFromURL* sub-process extracts the text information whether it is HTML or a file (pdf, doc or docx). A series of rules are applied that allow obtaining a clean text. *CheckWebPagesChanges* is responsible for detecting if a website has changed and it is necessary to reprocess. For this purpose, a CRC (*Cyclic Redundancy Check*) code is calculated from the text. *LoadDataURL* sub-process incorporates real information to a web, subdomain or portal as RDF triplets in *Virtuoso* (e.g. *ei2a:idWebPage rdf:type ei2a:WebPage*, *ei2a:idWebPage rdf:type owl:NamedIndividual*, *ei2a:idWebPage ei2a:URL url*). In *UpdateText* sub-process, after text preprocessing, in which some common task is performed such as lowercase transformation, stemming or stopwords filtering, the main NLP techniques used on textual data involve semantic classification based on thesaurus, text summary and recognition and classification of named entities (NERC). The text summary task offers a synthesis of the textual information with the most relevant sentences by means of graph-based ranking algorithms [15]. This avoids having to read the whole web to know what it is about. The NERC task, implemented in *PredictionNerSpark* sub-process, identifies, extracts and classifies implicit information of the texts related to people, organizations and locations that are named in them. This is possible thanks to the use of neural network algorithms [16]. In this case, the neural network known as the *Multi-Layer Perceptron (MLP)* has been used. To apply the mathematical model in charge of recognizing and classifying named entities, textual information is transformed

<sup>6</sup>Crawler4j library, <https://github.com/yasserg/crawler4j>, last accessed 2018/09/10

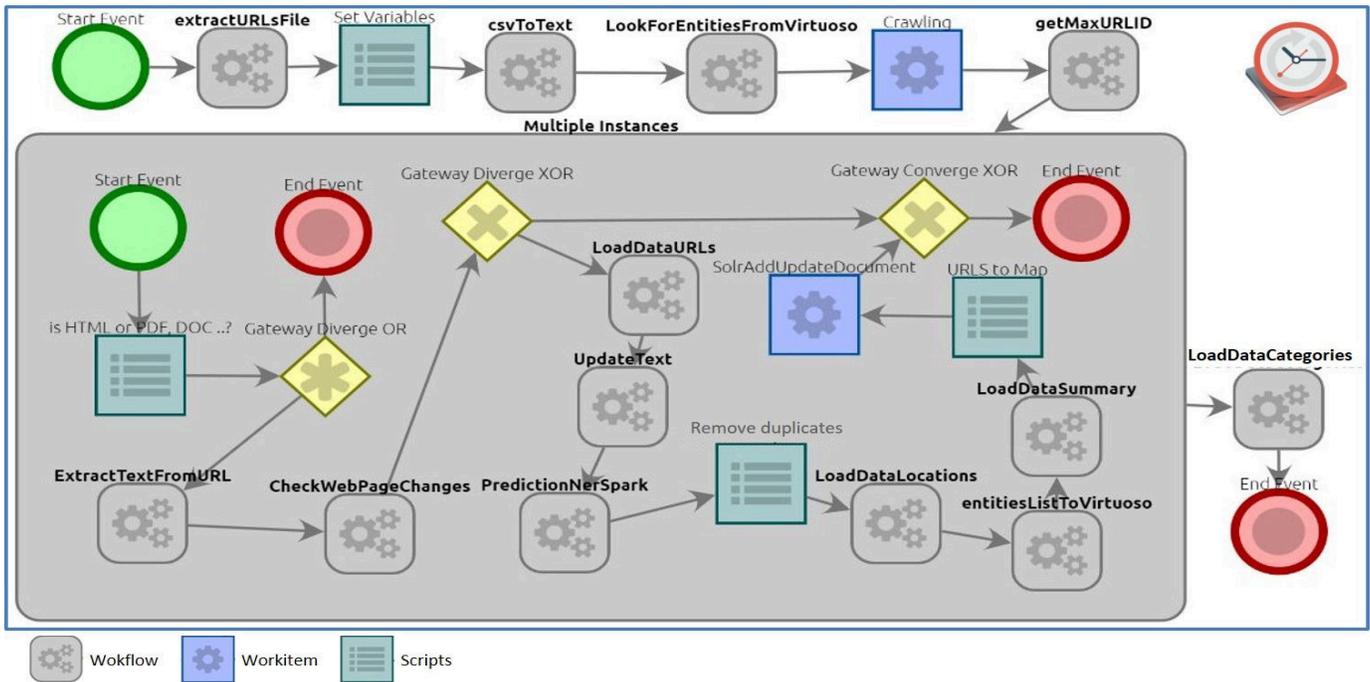


Fig. 2. Web crawling process.

into numerical representation, post-processed tasks are applied and a training set (or corpus) of formal informative type (news) has had to be built so that the model learns.

Identified the technical-legal framework applicable to the use of web crawling techniques, a methodology has been elaborated and followed for the extraction, treatment, storage, publication and reuse of institutional web information. The methodology takes into account aspects of crawling exclusion (file *robot.txt* and terms of use), intellectual property and protection of personal data. In fact, due to legal aspects, people extracted from the NERC technique, which do not belong to the organizational chart of the Government of Aragon (persons obtained through *LookForEntitiesFromVirtuoso* sub-process), is anonymized in the summary generated with asterisks. After that, extracted knowledge is stored in a structured and controlled manner in *Openlink Virtuoso* and *Solr NoSQL* databases for further exploitation. In *Openlink Virtuoso*, *LoadDataLocations* sub-process inserts through triplets all the locations previously extracted with the NERC technique, *entitiesListToVirtuoso* sub-process adds the citations, and that is, information regarding an entity (person, organization or location) is cited on a web, subdomain or portal, and *LoadDataSummary* sub-process introduces information related to the website summary. Finally, the url, CRC, categories in which a website is classified, the original text, the processed text, the current date, the summary and the persons, organizations and locations identified in the processed text, is stored in *Solr* database through the *SolrAddUpdateDocument* sub-process. Finally, the *LoadDataCategories* sub-process inserts in *Openlink Virtuoso* the data relative to the categories in which a website is classified.

#### IV. EI2A ONTOLOGY

In the government of Aragon an important volume of data begins to exist, and those elements such as the ontologies that contribute to the improvement of the structuring of the information and to the standardization of the data are increasingly important and relevant in the field of automation in information management systems. EI2A emerges with the main idea of generating a framework (a set of technical and legal rules) in which the open data and regional government data in general can begin to be automated in a much deeper way.

Borrowed from philosophy, ontology is a term that refers to an explicit and formal specification of a shared conceptualization [17]. It details the concepts and relationships of a domain allowing analyzing, sharing and reusing common knowledge. Ontology populated with high-quality instantiations provides a consistent knowledge base. With the knowledge of regional public administration experts, EI2A ontology has been defined and created using a process that follows the methodological guidelines contained in [18], [19]. Based on the philosophy of the Semantic Web, well-known ontologies, schemes and vocabularies such as [20]–[25] endorsed by European directives (INSPIRE)<sup>7</sup> and International Consortium (W3C)<sup>8</sup> have been reused to model EI2A ontology.

Institutional data of common interest identified and modeled are focused on concepts related to describe organizational structures, natural persons, any places in terms of its name, address or geometry, geolocations, territories, events, temporarily and documents (including web pages). In this way,

<sup>7</sup>Inspire, <http://www.idee.es/europeo-inspire>, last accessed 2018/09/10

<sup>8</sup>W3C, <https://www.w3.org/>, last accessed 2018/09/10

the ontology provides concepts and relationships to support the representation of a very broad range of organizational structures. It is possible to describe the notion of an organization, the decomposition into sub-organizations, departments and units and the purpose and classification of organizations. In addition, membership and reporting structure with an organization: roles, posts and relationships between people and organizations. Furthermore, locations information at which organizations exist (sites or buildings) and organizational history (merger, renaming). A Government of Aragon domain-specific extension has been added to model the nature of an organic unit or office in Aragon (level of administration, public or private character, etc.). EI2A model has been enriched with aspects and metadata of DIR<sup>9</sup> and ENI<sup>10</sup>. On the other hand, motivated by the need of automatic way to extract, structure and standardize information from the huge amount of textual content available on the institutional websites, EI2A ontology provides concepts and relationships to specify semantically information related to a recognized entity (person, organization and/or location) has been cited on a web classified under a categorization of Government of Aragon themes.

## V. RESULTS

To evaluate our work of gathering, analyzing, processing, storing and keeping updated unstructured institutional information to be offered to all interested collectives from a single access point in a public and structured way, 667 websites are been crawled in order to extract text content. In this section, results from a sampling of five websites (<http://www.educaragon.org>, <http://transparencia.aragon.es>, <https://www.turismodearagon.com>, <https://www.saludinforma.es> and <https://inaem.aragon.es/>), considered of greater relevance for the Government of Aragon and as seed of this approach, are presented as part of a larger experiment designed. The system is ready to add as websites as required. Through a periodic web crawling process, with a depth of 4 and 10 crawling-threads, 3,963 urls (HTML or a file) have been processed. Data extracted has been cleaned applying customized metadata removing rules such as headers, footnotes or indexes, and the texts have been processed (lowercase transformation, lemmatization or stopwords filtering) to prepare them for later application of NLP techniques (thesaurus-based semantic classification, named entities recognition and classification and, summarization).

To apply EI2A scheme on real data, the ontology has been populated with information from each institutional website. *Person*, *Organization*, *Site*, *Address*, *Location*, *Temporal Entity*, *WebPage* and *Citation* concepts have been populated with more than 95,978 new instances and relationships generated as triplets (subject-relation-object). Some of them provided by the NERC process. For example, information related to a recognized entity (person, organization and/or location) has been

<sup>9</sup>DIR, <https://administracionelectronica.gob.es/ctt/dir3>, last accessed 2018/09/10

<sup>10</sup>ENI, <https://administracionelectronica.gob.es/ctt/eni>, last accessed 2018/09/10

cited on a web classified under a categorization is specified semantically. In addition, data related to the url, the date of textual web content capture and the summary is added to EI2A. On the other hand, EI2A has been populated with information of the organizational chart of Government of Aragon extracted from a dataset<sup>11</sup> of Aragon Open Data portal. In this way, semantic information is added to indicate the nature of a person's membership of an organization, that is to say, that a person belongs to a unit or department with a specific role in a valid time interval. Results from extracting knowledge of web textual content are stored in a structured and controlled mode into *Solr* and *Openlink Virtuoso* NoSQL databases allowing future open access and simple data exploitation. Thanks to a web interface, as a semantic search engine in which it is able to understand through natural language type questions and generate appropriate responses to the context, it is possible to search information on the generated knowledge base and to browse through the ontological model EI2A. For example, Fig. 3 shows information about where a specific person is working and on which websites is cited: 'Francisco Javier Lambán' is President of Aragon since July 4, 2015 to the present, in the department 'The presidency' that has its headquarters in Paseo María Agustín, 36. This person has been cited on a pdf document classified in the *Dependency* and *SocialCareAndDependency* categories.

Experimental results based on institutional information validate that the proposed approach improves the structuring and standardization of decentralized data that can be processed and offered to all interested collectives through the application of web crawling, NLP and ontology-based techniques. EI2A has been populated with many high-quality instantiations, affording and securing new possibilities of generating valuable and consistent ontology-based knowledge services.

## VI. CONCLUSIONS AND FUTURE WORK

Governments are one of the main producers of information, which, in the exercise of their functions, create, collect, treat, store, distribute and disseminate large amounts of information of different fields. How to provide relevant elements that allow improving the structuring of institutional information and deepening its standardization to make easier its access and make use of the data has become an important challenge. In this paper, an approach based on ontology and the use of NLP techniques is proposed.

Despite dealing with texts with a great diversity of domains and formats, the work carried out manages to integrate a generic system capable of fulfilling the expectations presented at the beginning. Although improvements have been identified related to define new entities according to the context, the application of a more complex text pre-processing and the generation of different mathematicians models according to the text context would also imply the improvement in the extraction of information and in the quality of the structured and stored data, results obtained are significantly satisfactory.

<sup>11</sup>Organigram, <https://opendata.aragon.es/datos/catalogo/dataset/organigrama-del-gobierno-de-aragon>, last accessed 2018/09/10

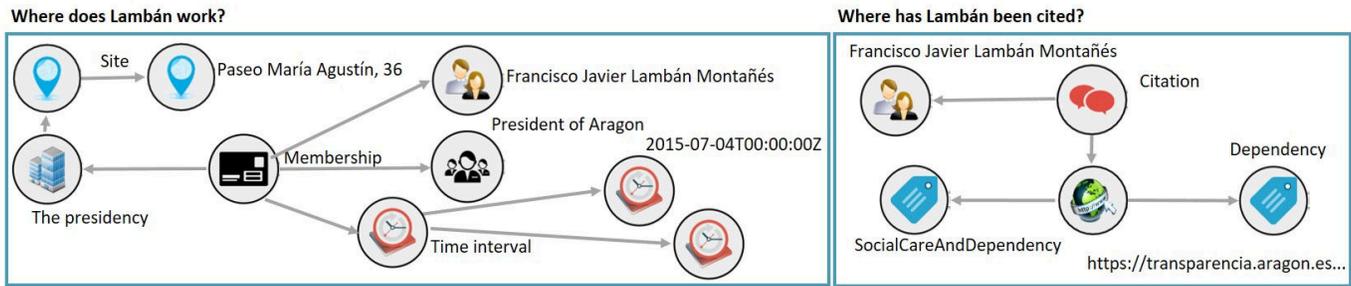


Fig. 3. Browser for EI2A ontology.

In this context, the viability of the proposed approach has been verified and new aspects have been detected in which it is necessary to continue exploring. The aim of the future work is to deploy the solution over the public Aragonese infrastructures in order to develop on top of this system new natural language recognition services with the challenge of deepening more in the understanding questions asked by a user and knowing what needs to be answered (for example, semantic search engine and assistant BOT). Moreover, to investigate new services in the line of extracting knowledge from the unstructured information that the Government of Aragon has, and to continue expanding and evolving the EI2A schema with the definition of new concepts and relationships based on the information processed as a consequence of the indicated actions.

#### ACKNOWLEDGMENT

This work has been partly funded by Innovation, Research and University Department of the Government of Aragon within Aragon Open Data project. Special thanks to General Direction of Electronic Administration and the Information Society, Iciar Alonso and Julián Moyano. Also, it has been partly financed by the FSE Operative Programme for Aragon (2014-2020).

#### REFERENCES

- [1] J. Hoxha and A. Brahaj, "Open Government Data on the Web: A Semantic Approach," *Emerging Intelligent Data and Web Technologies (EIDWT)*, 2011, pp. 107–113.
- [2] A. Gugliotta, V. Tanasescu, J. Domingue, R. Davies, L. Gutiérrez-Villarías, M. Rowlat, et al. "Benefits and challenges of applying semantic web services in the E-government domain". In *Proceedings of International Conference on Semantic Technologies (SEMANTICS 2006)*. Vienna, Austria.
- [3] R. Cyganiak (2014). Retrieved 2016, from The linking open data cloud diagram: <http://lod-cloud.net>
- [4] S. Bogdanović-Dinić, N. Veljković and L. Stoimenov (2014). "How open are public government data? An assessment of seven open data portals". In M. P. Rodríguez-Bolívar (Ed.), *Measuring E-government efficiency*, vol. V, pp. 25–44.
- [5] P. Milic, L.V. Stoimenov and N. Veljkovic, "Semantic Technologies in e-government: Towards Openness and Transparency". M.P. Rodríguez Bolívar (Ed.), *Smart Technologies for Smart Governments. Public Administration and Information Technology*
- [6] H. Alani, S. Kim, D. Millard, M. Weal, W. Hall, P. Lewis and N. Shadbolt. "Automatic Ontology-Based Knowledge Extraction from Webs Documents," *IEEE Intelligent Systems*, vol. 18, pp.14–21.
- [7] S. Handschuh, S. Staab, and F. Ciravegna. "S-CREAM Semi-Automatic Creation of Metadata," *Knowledge Engineering and Knowledge Management: Ontologies and the Semantic Web (EKAW 02)*. Lecture Notes in Artificial Intelligence, no. 2473, Springer-Verlag, Heidelberg, Germany, 2002, pp.358–372.
- [8] M. Vargas-Vera et al. "Knowledge Extraction Using an Ontology-Based Annotation Tool." *Workshop on Knowledge Markup and Semantic Annotation*. ACM, pp.5–12
- [9] P. Cimiano. "Ontology Learning and Population from Text: Algorithms, Evaluation and Applications". Springer-Verlag New or, Inc., Secaucus, NJ, USA, 2006.
- [10] R. Witte, N. Khamis and J. Rilling, "Flexible Ontology Population from Text: The OwlExporter," *Int. Conf. on Language Resources and Evaluation*. 2010.
- [11] J. Makki, "OntoPRiMa: A prototype for automating ontology population," *International Journal of Web/Semantic Technology (IJWesT)*. Vol. 8, October 2017.
- [12] D. Maynard, Y. Li and W. Peters, "NLP Techniques for Term Extraction and Ontology Population." Vol.167. *Ontology Learning and Population: Bridging the Gap between Text and Knowledge*, pp. 107–127.
- [13] J. Makki, A-M Alquier and V. Prince, "Ontology Population via NLP Techniques in Risk Management," *International Journal of Industrial and Manufacturing Engineering*. 2008.
- [14] P. Peña, R. del Hoyo, J. Veja-Murguía, J. I. Calvo and J. M. Martín, "Moriarty: Improving 'time to market' in Big Data and Artificial Intelligence applications," *Proceedings of the International Conference on Big Data*. Alicante (Spain). International Journal of Design & Nature and Ecodynamics, 11(3), pp. 230-238, 2016.
- [15] G. Erkan and D. R. Radev, "Lexrank: Graph-based lexical centrality as salience in text summarization," *Journal of Artificial Intelligence Research*, 22:457-479, 2004.
- [16] J. P. Chiu and E. Nichols, "Named entity recognition with bidirectional lstm-cnns. *arXiv preprint arXiv:1511.08308*". 2015.
- [17] T. R. Gruber. "Toward Principles for the Design of Ontologies Used for Knowledge Sharing," *International Journal of Human and Computer Studies*, 43 (5-6), pp.907–928, 1992.
- [18] M. Fernández-López, A. Gómez-Pérez and N. Juristo, "METHONTOL-OGY: From Ontological Art Towards Ontological Engineering," Spring Symposium on *Ontological Engineering of AAAI*. Stanford University, California, pp 33-40, 1997.
- [19] N. F. Noy and D. L. McGuinness, "Desarrollo de Ontologías-101: Guía Para Crear Tu Primera Ontología." Standford University. United States, September 2005.
- [20] The Organization Ontology, <https://www.w3.org/TR/vocab-org/>, last accessed 2018/09/10
- [21] Simple Knowledge Organization System, <https://www.w3.org/2004/02/skos/>, last accessed 2018/09/10
- [22] Dublin Core Metadata Initiative, <http://dublincore.org/documents/dcmi-terms/>, last accessed 2018/05/18
- [23] ISA Person Vocabulary, <https://www.w3.org/ns/person>, last accessed 2018/09/10
- [24] ISA Location Vocabulary, <https://www.w3.org/ns/locn>, last accessed 2018/09/10
- [25] The Event Ontology, <http://motools.sourceforge.net/event/event.html>, last accessed 2018/09/10



# Participatory Design with On-line Focus Groups and Normative Systems\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Marlon Cárdenas

*Universidad Complutense de Madrid*  
Madrid, Spain  
marlonca@ucm.es

Noelia G. Castillo

*Universidad Complutense de Madrid*  
*CMI Business School and EAE Business School*  
Madrid, Spain  
ngarc02@ucm.es

Jorge Gómez-Sanz

*Universidad Complutense de Madrid*  
Madrid, Spain  
jggomez@ucm.es

Juan Pavón

*Universidad Complutense de Madrid*  
Madrid, Spain  
jpavon@ucm.es

**Abstract**—Participatory design is a generally accepted practice for the construction of Ambient Assisted Living (AAL) systems. The involvement of experts and users in the conception and design of assistive solutions can lead to better systems. A common technique to involve users is called focus-group, which is mainly a moderated group meeting. Despite its benefits, it cannot be neglected the implicit cost of preparing and performing such meetings, and ensuring, later on, that the resulting assistive solution meets the requirements. A disruptive way to change this situation is the application of ICT technologies. This work contributes with a proposal for partial automation of focus-group techniques that support on-line evaluation of assistive solutions during the conception stage. Also, the paper addresses the formalization of the evaluation feedback through the use of normative systems.

**Index Terms**—



# An analysis of the perception of intelligence by different stakeholders in the Ambient Assisted Living domain

Marlon Cárdenas Bonett  
Facultad de Informática  
Universidad Complutense de Madrid  
Madrid 28040  
Email: marlonca@ucm.es

Noelia García Castillo  
Facultad de Informática  
Universidad Complutense de Madrid  
Madrid 28040  
Email: ngcastillo@ucm.es

Jorge J. Gómez Sanz  
Facultad de Informática  
Universidad Complutense de Madrid  
Madrid 28040  
Email: jjgomez@ucm.es

**Abstract**—This paper analyzes the perception of Artificial Intelligence of different stakeholders in Ambient Assisted Living creations. This perception has been widely addressed in the area of Human Robotics Interaction, but less in the Ambient Assisted Living. The study includes some insights in the industrial creation of such systems, but it focus in on a survey to Artificial Intelligence students, the future creators of these solutions; and a qualitative analysis of end-users reaction when asking about their impression about using intelligent technology. A conclusion is that early adopters tend to see AI everywhere, while industrial engineers hardly feel the need to pointing out explicitly the intelligence within. A reason for this could be the conservative stance of end-users, mostly older people, that do not understand the benefits and it may even act as deterrent. On the other hand, professionals, such as physiotherapists, are more positive towards the role of intelligence, and start imagining possible applications, just as the students in AI.

## I. INTRODUCTION

The development of Ambient Assisted Living (AAL) is a multidisciplinary one where experts from different disciplines get together in order to improve the quality of the daily living of people and, in particular, those with special needs. As researchers in this area, we have concerns about the functionality such systems ought to provide and how it is perceived by the end-users. Current approaches for developing such systems are highly driven by how end-users interact with the inventions. This is the user-centric approach that is evolving to a co-creation scenario [1]. Modeling the scenarios, as in [2], can help to foster discussion about how we want the system to be. In particular, it makes sense to wonder how intelligence is used, how it is perceived by the different stakeholders, and if it is positive or not to be explicit about the presence of intelligence in one's invention.

The stance of the paper is a social science based one, which differs from personal views of AI contributions, such as [3], or more general reviews of what is AI according to textbooks, such as [4]. When the problem is to determine what is the perception of an issue, readers should get rid of the bias of their own beliefs about such issue. And approaches to capture the perception of intelligence, should follow social sciences based techniques, instead.

That humans do invent intelligence and tend to assume there is some even when there is not, has been known for a while. Brooks [5] put this idea in words: the intelligence is in the eye of the beholder. Besides, the concept of intelligence changes along the years. What is considered as intelligent in the 90's may considered quite usual in the 21st century.

After all, humans are very sensible to the perception of intelligence. They are very likely to show biased opinions depending on external factors. Works in psychology have identified how we perceive different intelligence on people depending on how they dress [6], or their bodily movements [7], to cite some. It would not be a surprise if subtle changes in our systems may make others think that a behavior is more or less intelligent.

In fact, an active area in the study of human perception of intelligence is Human Robotics Interaction (HRI). Duffy [8] discusses, but not explores empirically, how, by making robots look more human (e.g. through shape or by making them execute typical human actions such as walking), robots are perceived to be more intelligent. The goal would be achieving social interaction (hand shaking, dialogues, and more complex interactions). Sabanivic [9] uses observational studies to analyze interactions with humans in the open, concluding that the physical context of the interaction matters, that gaze is part of the communication, and that robot to many interactions are needed.

HRI is not ambient intelligence, though some conclusions could be reused. Most HRI results require an embodiment of the intelligence a.k.a. the robot. In ambient intelligence, there are networks of distributed sensors and actuators, and there is not necessarily a visible body to interact with. Nevertheless, HRI results are relevant to Ambient Assisted Living, though grounding them is needed. In particular, there are misconceptions on technology related to AAL as seen by experts, practitioners, and end-users. For instance, if users think there is intelligence in an AAL facility, do they perceive the AAL system as a better one?

Needless to say that intelligence is a word frequently occurring in the academy papers. However, industry does not

share this attitude. If patent registries can be regarded as a one representative of industrial view of AAL, a likely hypothesis is that it does not care much about what is intelligence anyway in the AAL. Within this broad area, activity recognition problems are quite frequent in the AAL literature and one can find many patents about this. Classifying and recognizing activity patterns has a wide and varied use in different devices and monitoring and tracking systems [10] and is a frequent topic in ambient intelligence. Focusing in on this specific topic, a set of patents were obtained from Google Patents service looking for keywords related with “activity recognition” or “body movements”, and combined with others such as “daily living” or “patient”. First pages of queries were inspected looking for highly related patents to the attention of patients. This filtering led to 46 relevant patents, though limited to european and EEUU registries. Only five patents did cite intelligence explicitly as part of the invention. In the few patents that explicitly identify artificial intelligence, there is no distinguishing characteristic with respect to other patents that perform a similar function. This is a minor revision, but it is instructive preliminary analysis of how “intelligence” becomes less a buzz word in the patent literature. For the current paper, it is a good starting point to wonder if there is a path from early practitioners towards this final situation, where functions that need to be characterized as intelligent by people, are no more extraordinary than a mathematical function when they become experienced practitioners. This justifies some groundwork on AAL to check the prejudices of early practitioners of artificial intelligence.

Similarly, technology aversion [11][12][13] plays an important role in the co-creation of AAL inventions. Some analyses from the literature produce informing evidences for understanding how intelligence is perceived. To these, this paper wants to contribute with a qualitative analysis obtained from interviews made to Parkinson patients and health professionals.

Our conclusions on both sides of the study can be summarized in a very different attitude between the early practitioners (very enthusiastic about AI) and the end-users (indifferent or with some aversion). Also between the academy (aiming to create intelligence every time) and the industry (forgetting about the intelligence itself and focusing more on the services). The work makes extensive use of social sciences methods and contributes with qualitative analysis of the results.

The paper does not contain a dedicated related work section because it has been preferred to distribute the references along the report. Section II addresses the perspective of early practitioners obtained through some surveys and short experiments. Section III reviews some interview transcripts and the literature to gain some insights in how end-users and experts perceive the intelligence. Section IV includes the conclusions of the paper.

## II. PERCEIVED INTELLIGENCE BY EARLY PRACTITIONERS

To address the perception of intelligence by early practitioners, a survey has been conducted to undergraduate students of

the Computer Engineering Degree at Complutense University of Madrid. The survey combined open questions and scale-like questions. They have been asked about the presence of intelligence in different contexts. The survey was conducted into two different days. In the first day, 23 students were asked during a class, and then 33 undergraduate students participated in an online survey. The second day, 28 participated.

### A. First day

The first day of the Smart Systems subject, 23 undergraduate students were asked to provide with an example of artificial intelligence application they knew. For this survey, a microblogging tool was used. No format was assumed, just a limitation of 170 characters. The professor graded each answer following this scoring criteria: 0 (wrong concept, badly expressed), 1 (wrong concept, but well expressed), 2 (right concept, but badly expressed) and 3 (right concept and correctly formulated). The results are presented in figure 1.

All students declared that they did not have any experience in artificial intelligence. Therefore, it is of significant meaning that 86% of students provided examples that included, at least, an understanding of artificial intelligence that the professor approves.

Thus, considering their inexperience in the area of artificial intelligence, it is evident that they should have received some kind of training or instruction from some agent of socialization, either family, peers, mass media or some kind of formal or informal education. This hypothesis could be reinforced by the fact they chose a computer science degree.

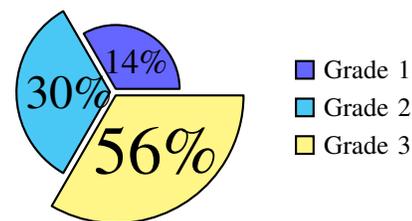


Figure 1. Grades received when suggesting an example of application of IA. The higher the grade, the better.

After the mentioned exercise of spontaneous examples of artificial intelligence, 33 students of two degree subjects, Smart Systems and Software Engineering, filled in a survey in which they were asked if they thought that six concrete devices had some artificial intelligence within. Answers followed a Likert Scale - a unidimensional scaling method that is one of the most commonly used scales in survey research [14]. For each question, the researchers formulated a statement that respondents had to evaluate: *Do you agree with the idea that Artificial Intelligence is used in the following examples?*

- 1) Algorithm of recommendation of a portal of films.
- 2) Fall detector for older adults.
- 3) Global Positioning System.
- 4) Cardiac pacemaker.



- 5) Controller for the body position and body movement in a video game.
- 6) Watch with location services for older adults.

The question aimed to explore the perception of the implicit AI in different devices, most of them directly related with AAL applications. Second and fifth devices were written thinking about sensors used to identify bodily positions in different contexts (gaming vs fall detection). Third and sixth devices used location services in general (just thinking about GPS) and in a AAL context (location services for older people). Fourth question was a control one. Since it was assumed a cardiac pacemaker ought not to involve a relevant amount of AI in general, respondents were expected to disagree. The first question was a control one too, but a positive control this time. It was intended to provide a positive answer about the use of AI in a classical film streaming service used at home.

It was expected that an expert would strongly agree to the presence of AI in the first, second, fifth, and have concerns about the sixth (a watch with location services can have multiple uses); and disagree/strongly disagree in the fourth case. The students' performance was different. In general, the students, see figure 2, identified correctly the objective presence of AI in the positive examples. In the case of the algorithm of recommendation, there is a 75.8% expressed partial or strong agreement while none of them selected strong disagreement. The percentage of right answers in the fall detector is even higher (84.9%). In the last of the objective AI examples, the controller of the body position and movement of a video game, there is a 15.2% of partial disagreement, but right questions are still considerably higher with 78.8%.

These positive results were lower in effectiveness than the results obtained from the open question from figure 1. Our conclusion is that students have a correct knowledge of success cases of AI techniques. However, when asked to evaluate a particular case, such as the chosen devices, some of them still fail to recognize the presence of AI.

Control questions returned unexpected results, as shown in figure 3. The GPS device received the same amount of votes to the agreement (total & partial agreement) with 39.4% and disagreement (total & partial) with 39.4%. The cardiac pacemaker is less evident, but it showed anyway a 51.5% of agreement (total & partial) and a 36.4% disagreement (total & partial). In the watch device, the votes are mostly positive (45.4% of votes) though there is a surprising uncertainty of 27.3 & of votes.

It is natural to have doubts when answering the last question about the role of AI in a watch. However, the variety of answers for the GPS or pacemaker cases was unexpected. Even though respondents were not questioned about the reason why they had chosen this answer, we elaborated an hypothesis: students were biased to think there was AI. The specific application to the health or medical area or its appearance in the context of an AI survey, as well as other intervening variables that are out of researchers' control, may have fostered those false positives. This could be the case of the watch locator for older adults, associating it with other smartwatches' char-

acteristics that were not mentioned in the survey statement, such as emergency help or activity recognition. Something similar could have happened to students in the GPS case. Some students may have thought of driving or city map applications and how they guide them, which could be regarded as an intelligent behavior. Other possible explanation is that they think about GPS just as the satellite network.

In either case, many students decided there was AI in those devices, almost as many as the ones deciding there is not. Whatever the reason, we interpret these false positives as a tendency to observe AI in any case. This would fit the theory that our perception of intelligence can be affected by the context and other variables, as in the effect of how we are perceived differently depending on how we dress [6].

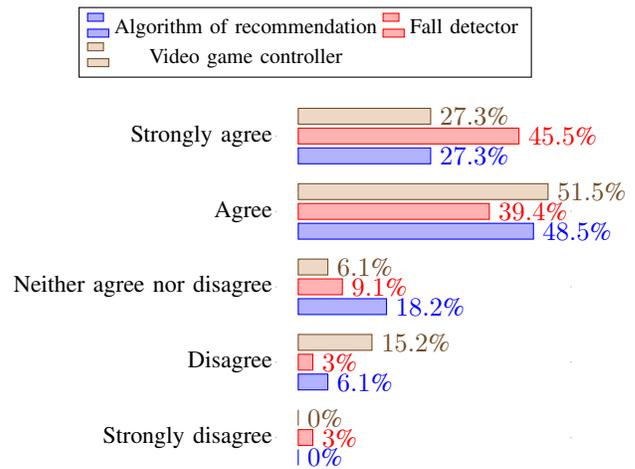


Figure 2. Expected positive cases in perception of AI presence.

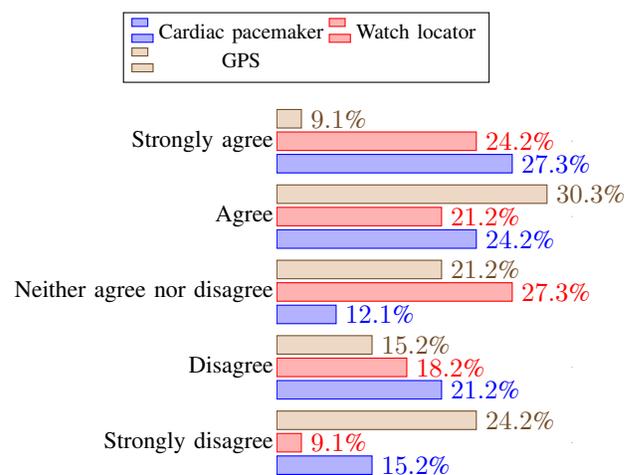


Figure 3. Expected negative cases in perception of AI presence.

## B. Second day

While the first day the effort was focused on text based questions, this time a visual/auditive stimulus was used. This experiment aims to proof that a system providing the same functionality may convince observers to involve more or less or more AI depending on how it is presented.

The experiment subjects were a group of 28 students of the Smart Systems subject, most were from 20 to 25 years old. They were shown the same video twice, though the second time it involved additional voice tracks. The students were informed about what the videos were about. Both videos depicts a case of midnight sleep disorder which may happen to those developing Alzheimer's disease. In both cases, the informing text is the following: *A person wakes up in the middle of the night. When he/she gets up, the lights turn on as this person moves from one place to another. It is decided that he/she may not be aware of what is doing and the person is asked if he/she is disoriented.*

Students were asked "Do you agree with the idea that Artificial Intelligence is applied in this scene?". Students watched the first video and answered the question. Then, the second video was presented followed by the same question again.



Figure 4. Fragment of the video used for the experiment.

Both videos represented the same course of action and, visually, were identical and looked like the figure 4. The differences between the first and the second video where the background dialog as follows:

- Video 1: Opening text: "The patient wakes up"
  - Audio: (after a time) "It seems that you are disoriented"
- Video 2. Opening text: "The patient wakes up"
  - Audio 1: "Let me turn on the light of this room"
  - Audio 2: "I turn on the light of the bathroom"
  - Audio 3: "You are wandering and it is 3 a.m."
  - Audio 4: "It seems that you are disoriented"

The answers are presented in figure 5. It should be remarked that the video depicted exactly the same scene. Only the second added three more audio tracks providing hints on what was being done. For instance, if the lights in the first video just lighted on, the extra audio indicated in the second video that lights were going to be lighted on.

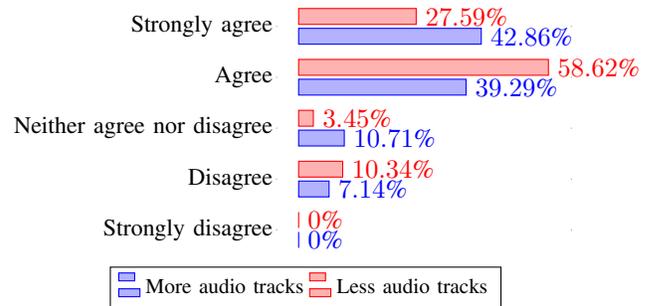


Figure 5. Perception of AI using videos with textual and audio information. 28 participating students.

The sum of those students who strongly agree that there is AI in the video plus those that only agree is roughly the same (86.21% first video against 82.15% in the second). However, the decisiveness in strongly assessing the presence of AI technology, changes remarkably, from a 27.6% in the first video to a 42.9 % in the second one.

It could be concluded that a 15% of the undergraduate students were deceived by the voice audio of the second video, or more if the transference of votes from disagree to neither both is accounted. The same functionality, when explained by an artificial voice, led the students to believe the AI was more relevant in the second video than in the first.

## III. END-USERS ATTITUDES TOWARDS INTELLIGENCE IN AAL

The end-users for AAL can be just anyone, but it is frequent that engineers focus on older people. This is a concern because the attitude of older people is more sensible towards technology and we expect Artificial Intelligence to be specially challenging to understand and to welcome.

A first analysis (section III-A) has been made reusing interviews obtained from project (Name omitted for the sake of blind review). This provides an insight on the reaction towards the intelligence on behalf end-users.

Then, a second analysis (section III-B) focused on the literature was made. There is an relevant amount of results on technology aversion in the literature. However, the specific topic of intelligence, its perception and reaction towards it, is not so common.

### A. Analyzing interviews

In a past project about AAL that involved Parkinson's patients and other end-users (SociAAL Social Ambient Assisted Living, TIN2011-28335-C02-01)[15][16], 27 in-depth interviews were conducted to gather qualitative data about the Parkinson's disease. Some interviews involved more than one individual, but, in total, there were 5 Parkinson's disease experts (two neurologists, two psychologists and one physiotherapist), 13 Parkinson's patients (stages 3 and 4 of the Hoehn



and Yahr scale) and 9 caregivers [17]. Those semi-structured, in-depth interviews included questions about the daily lives, main symptoms and limitations, activities of the caregivers and the perception of Ambient Assisted Living technologies. The youngest interviewed individual patient was 59 and the eldest one was 75. Half of them were male and half were female. All patients and caregivers lived in the Community of Madrid (Spain) with different social and cultural backgrounds.

For the present paper, we have analyzed in greater depth the transcriptions of these interviews to know of their stance towards intelligence. Interviewers were social scientists who were involved in the project, so they had knowledge that intelligence played an important role in the systems to be developed. The interviews were semi-structured ones, with a script oriented towards knowing more of their needs and how technology could aid them. Sometimes, the interviewer asked directly the interviewed about the role of some intelligent technology.

The transcriptions were reviewed looking for mentions of “intelligence” and “intelligent”. These terms were used in 10 of the 27 interviews (6 interviews with patients/caregivers and 4 interviews with professionals, one of them with two professionals at the same time). None of the patients or caregivers brought this topic in, and, in all cases it was the interviewer who did it. When talking with the experts, the result was the opposite in two of the three cases. Once the topic appeared, the reactions were different.

Patients or caregivers do not answer using those terms “intelligent” or “intelligence” when they are suggested by interviewers. All of them belong to either lower middle class or upper middle class. Furthermore, if the topic of artificial intelligence was addressed, some patients and caregivers associated it with high cost (“That’s for people that have a lot of money”, “But that is not accessible to all”, “Nobody would give financial help for that”), distant future (“It sounds like a house of the future”) and other personal circumstances (“I can’t be left on my own”). Nevertheless, a patient maintained that he agreed with all ways to keep up-to-date and a caregiver -a patient’s wife- claimed she would be capable of getting used to such a system.

When considering experts, three of five had reactions towards the term “intelligence”. Two used pro-actively the word “intelligent” without being questioned, and one was asked about the “intelligence” directly.

The interviewer asked a physiotherapist about the interest of an intelligent system. The physiotherapist answered that it was a great idea, but then she questioned to what extent it was useful, for instance, to perform activities instead of the patient, because it was good for the patient to exercise themselves. However, the assistance oriented towards monitoring and to actively remind the patient was more positively received. In one case, the therapist started playing with the idea and imagining things an *intelligent house* could do.

A psychologist used the word “intelligent” but was reluctant to elaborate and immediately grounded the term to things done within projects this psychologist was involved into

(identify patient’s situation to recommend physical exercises, handwriting analysis, cognitive training). She knew of the subject and the necessary technology. A neurologist also used the word “intelligent” when referring to adaptability (amount of medicine an intelligent pump system has to supply, or apps with smart-phones that have access to multiple sensors). In both cases, the question was a generic one about their prior knowledge on relevant technologies for AAL, like domotics.

The first conclusion is that words like “intelligence” or “intelligent” are not likely used by patients or caregivers, but by interviewers and experts. Also, that experts can be already familiar with the term and that it is inherently associated with technology. They do not elaborate too much about it, but, with the exception of the physiotherapist, the neurologist and the psychologist seem more aware of what it really can do. They identify specific functions and catalog them as intelligent ones because of the presence of capabilities like adaptiveness, handwriting recognition, or sensor processing capabilities, to cite some.

Patient and caregivers are less receptive to words like “intelligence” or “intelligent”. As it has been shown, they do not use it despite the social class they belong to. They tend to think it is something expensive and do not elaborate much about what they can do with it. This may be related with the technology aversion which will be analyzed in section III-B .

### B. Analyzing the literature

It is hard to evaluate how much intelligence contribute to the technology aversion identified by the literature. The factors and barriers for the acceptance of technology for Ambient Assisted Living that were collected in the interviews to Parkinson’s patients coincided with the results of previous researchers [11][12][13].

Among the scientific literature gathered, Peek et al. [13] carried out a systematic review of 16 articles, obtaining as a result 27 factors of acceptance in the pre-implementation stage of technology for aging at home. These factors are summarized by the authors in six items [13]: “concerns regarding technology (like cost, privacy and usability); expected benefits of technology (like safety and perceived usefulness); need for technology (e.g., perceived need and subjective health status); alternatives to technology (e.g., help by family or spouse), social influence (e.g., influence of family, friends and professional caregivers); and characteristics of older adults (e.g., desire to age in place)”.

Intelligence requires data obtained from the user contexts. Jaschinski and Allouch’s [12] study expounds on these technological concerns related to privacy for personal information, security, possible intrusion of too visible devices or constant surveillance. Other barrier that is gathered by the authors is the lack of user control reinforced by elderly people’s technological inexperience that leads to technology anxiety. Finally, and according to this compilation, intelligent technologies “cannot and should not replace human assistance and human interaction”, especially in aspects related to personal care tasks, leisure activities and most health related tasks [18].

## IV. CONCLUSIONS

Addressing the role of intelligence in a area like Ambient Assisted Living ought to be a concern in a development. This work has contributed with an analysis of the perception of intelligence from two perspectives: as it is perceived by the future creators of AI technologies, and as it is perceived by other stakeholders of these systems (end-users and experts). This research was made within the context of Ambient Assisted Living systems, i.e., systems that aim to assist users to improve the quality of their daily living.

The end-users have shown unemotional reaction when someone uses the word “intelligent”. They have assumed it is expensive and do not incorporate that word into their responses. Being people of 59 and older, this may seem natural. The experts’ opinion is more positive and in two of the cases the experts pro-actively brought the topic of intelligence in a very accurate way. In these cases, experts had prior knowledge because they were working in similar areas.

This stance contrasts with the new practitioners and engineers, that enthusiastically tend to see intelligence everywhere. However, the industry, when registering inventions, do not highlight the intelligence they incorporate in the devices. They prefer most of the time to focus on the capability without concern of whether this brings intelligence or not.

From the social sciences view, the population of this study is a minimal one. Despite the size, the results are still better than one’s intuition about the problem and can be of some value when addressing an AI related project. They can foster additional thinking about this issue so that engineers do not assume different stakeholders (developers, end-users, and experts) share the same view on AI. More results are still needed, but these are inspiring enough to continue this research.

## ACKNOWLEDGMENT

We acknowledge support from the project “Collaborative Ambient Assisted Living Design (ColoSAAL)” (TIN2014-57028-R ) and “Collaborative Design for the Promotion of Well-Being in Inclusive Smart Cities” (TIN2017-88327-R) funded by Spanish Ministry for Economy and Competitiveness; and MOSI-AGIL-CM (S2013/ICE-3019) co-funded by Madrid Government, EU Structural Funds FSE, and FEDER.

## REFERENCES

- [1] M. Pallot, B. Trousse, B. Senach, and D. Scapin, “Living lab research landscape: From user centred design and user experience towards user cocreation,” in *First European Summer School “Living Labs”*, 2010.
- [2] P. Campillo-Sánchez and J. Gómez-Sanz, “Modelling and simulation of alzheimer’s disease scenarios,” *Procedia Computer Science*, vol. 83, pp. 353–360, 2016.
- [3] L. Deng, “Artificial intelligence in the rising wave of deep learning: The historical path and future outlook [perspectives],” *IEEE Signal Processing Magazine*, vol. 35, no. 1, pp. 180–177, 2018.
- [4] S. J. Russell and P. Norvig, *Artificial intelligence: a modern approach*. Pearson Education Limited., 2016.
- [5] R. A. Brooks, “Intelligence without reason (ai memo no. 1293),” 1991.
- [6] D. U. Behling and E. A. Williams, “Influence of dress on perception of intelligence and expectations of scholastic achievement,” *Clothing and Textiles Research Journal*, vol. 9, no. 4, pp. 1–7, 1991.
- [7] N. A. Murphy, “Appearing smart: The impression management of intelligence, person perception accuracy, and behavior in social interaction,” *Personality and Social Psychology Bulletin*, vol. 33, no. 3, pp. 325–339, 2007.
- [8] B. R. Duffy, “Anthropomorphism and the social robot,” *Robotics and autonomous systems*, vol. 42, no. 3, pp. 177–190, 2003.
- [9] S. Sabanovic, M. P. Michalowski, and R. Simmons, “Robots in the wild: Observing human-robot social interaction outside the lab,” in *Advanced Motion Control, 2006. 9th IEEE International Workshop on*. IEEE, 2006, pp. 596–601.
- [10] D. Figo, P. C. Diniz, D. R. Ferreira, and J. M. Cardoso, “Preprocessing techniques for context recognition from accelerometer data,” *Personal and Ubiquitous Computing*, vol. 14, no. 7, pp. 645–662, 2010.
- [11] H. Hawley-Hague, E. Boulton, A. Hall, K. Pfeiffer, and C. Todd, “Older adults perceptions of technologies aimed at falls prevention, detection or monitoring: a systematic review,” *International journal of medical informatics*, vol. 83, no. 6, pp. 416–426, 2014.
- [12] C. Jaschinski and B. Allouch, “S.: Ambient assisted living: benefits and barriers from a user-centered perspective,” *Proceedings of Ambient*, 2014.
- [13] S. Peek, E. J. Wouters, J. van Hoof, K. G. Luijckx, H. R. Boeije, and H. J. Vrijhoef, “Factors influencing acceptance of technology for aging in place: A systematic review,” *International Journal of Medical Informatics*, vol. 83, no. 4, pp. 235–248, 2014.
- [14] R. D. Wimmer and J. R. Dominick, *Mass media research*. Cengage learning, 2013.
- [15] M. Arroyo, L. Finkel, and J. J. Gomez-Sanz, “Requirements for an intelligent ambient assisted living application for parkinson patients,” in *International Conference on Practical Applications of Agents and Multi-Agent Systems*. Springer, 2013, pp. 441–452.
- [16] I. García-Magariño and J. J. Gómez-Sanz, “An ontological and agent-oriented modeling approach for the specification of intelligent ambient assisted living systems for parkinson patients,” in *International Conference on Hybrid Artificial Intelligence Systems*. Springer, 2013, pp. 11–20.
- [17] M. A. Menéndez, T. C. López, and L. F. Morgenstern, “El tecno-cuidado en hogares con mayores dependientes con enfermedad de parkinson,” *Teknokultura*, vol. 11, no. 1, pp. 143–165, 2014.
- [18] J. Van Hoof, H. Kort, P. Rutten, and M. Duijnste, “Ageing-in-place with the use of ambient intelligence technology: Perspectives of older users,” *International journal of medical informatics*, vol. 80, no. 5, pp. 310–331, 2011.



# Computational machines, free will and human reason

Gonzalo Génova

Departamento de Informática  
Universidad Carlos III de Madrid, Spain  
[ggenova@inf.uc3m.es](mailto:ggenova@inf.uc3m.es)

Ignacio Quintanilla Navarro

Departamento de Teoría e Historia de la Educación  
Universidad Complutense de Madrid, Spain  
[ignacioq@ucm.es](mailto:ignacioq@ucm.es)

**Abstract**—David Hume, the Scottish philosopher, conceives reason as the slave of the passions, which implies that human reason has predetermined objectives it cannot question. An essential element of an algorithm running on a computational machine (or Logical Computing Machine, as Alan Turing calls it) is its having a predetermined purpose: an algorithm cannot question its purpose, because it would cease to be an algorithm. Therefore, if self-determination is essential to human intelligence, then human beings are neither Humean robots, nor computational machines.

**Keywords**—human nature; free will; self-determination; algorithm; computational machine; goal and strategy selection

## I. INTRODUCTION

In this paper we want to show the connection between Hume's conception of human nature and the modern conception of robots. Even if, quite possibly, the concept of 'robot' would have proved deeply strange to Hume, the truth is that his conception of reason as 'the slave of the passions' anticipated the modern concept of computing machine: we call his conception a *Humean robot*, that is, an instrumental intelligence at the service of predetermined objectives, or passions. In fact, if for us humans of the 21st century, it is tempting to consider ourselves complicated biological robots, it is only because we have previously accepted the Humean paradigm of reason as the slave of the passions. We are prone to believe that we are robots, because we have first accepted that reason neither chooses nor prioritizes its ends.

This paper is a summary of the one published in the Journal of Experimental & Theoretical Artificial Intelligence (Jan 2018) with the title *Are Human Beings Humean Robots?* [2].

## II. DAVID HUME: REASON IS THE SLAVE OF THE PASSIONS

David Hume (1711-1776) wrote in *A Treatise of Human Nature*, under the section devoted to the influencing motives of the will, that "reason is, and ought only to be the slave of the passions, and can never pretend to any other office than to serve and obey them" [6]. Hume wanted to understand the human mind as Isaac Newton had understood the cosmos, by adopting a mechanistic approach to human intelligence. Human beings are attracted by passions, and moving towards a concrete passion can be resisted only with aid of a stronger and opposite passion, much in the same way as physical forces operate on bodies. In this conception of human nature, *the role of reason is to elaborate a strategy* to best fulfill the set of passions; but reason neither questions nor chooses the passions it has to serve. We think Hume proposes a suggestive account

of instrumental reason that anticipates and prepares a modern algorithmic model of intelligence, aimed at optimizing the achievement of its predetermined objectives (i.e. passions).

In Hume's sentimentalist approach to ethics, happiness is achieved when passions are satisfied. In this model, *reason is understood primarily as an optimization tool* (technical or instrumental reason, therefore), used to calculate the behavior that better satisfies the passions involved and that demands less effort from the subject. *Reason is the slave of the passions*: it does not question those passions that are irresistibly imposed upon it, nor their objectives, nor the strength of their attracting force; passions and objectives are pre-rational or meta-rational.

If Reason is integrated into the realm of passions, or goals, as an algorithmic calculation, Will cannot be anything but automatic: once the optimal path is known, all that is left is to start out, give the order, but not properly 'decide'. What is implied here is a *radical denial of human freedom* in the usual sense of the term, to which we will refer later.

## III. ALAN TURING: WHAT IS A COMPUTATIONAL MACHINE

A robot is usually defined as a mechanical device that is controlled by a computer running a program; a robot is, in this sense, an algorithmic or computational machine. An algorithm can be preliminarily defined as a rule-based procedure that obtains a desired result in a finite number of steps. Alan Turing laid the foundations of the modern notion of algorithm, establishing that a computation method is *effective* (a.k.a. mechanical) if it can be carried out by a Turing Machine [8], or, as Turing himself calls it, a Logical Computing Machine [9]. This is the substance of the Church-Turing thesis [1].

However, and perhaps surprisingly, there is a lack of satisfactory consensus on the definition of algorithm [10]. A recent study by Hill [4] examines existing approaches to the notion of algorithm, from semi-formal definitions like the one by Donald Knuth, "an algorithm is a finite set of rules that gives a sequence of operations for solving a specific type of problem" [7], to more formal ones.

After some analysis, Hill offers a definition: "An algorithm is a finite, abstract, effective, compound control structure, imperatively given, *accomplishing a given purpose* under given provisions." The italics manifest the *intentionality* of algorithms. This sense of utility or purposefulness is shared by machines in general. It is the success or failure in accomplishing its function that permits us to tell whether the machine works properly or not. Thus, *a machine cannot be defined and accounted for without reference to its purpose* [3].

Take for example a game playing machine, designed to play against a human. Initially, the machine has the goal to win the game. If the game is very simple (like Tic-Tac-Toe), designing a strategy (an algorithm) to win, or at least not to lose, is rather easy. In the case of chess, the complexity of the game has not permitted, until now, an infallible strategy, even though, with current technology, most of human players will lose against a rather common artificial chess player.

A somewhat different kind of chess machine might include a certain degree of randomness in its ‘decisions’, or it might be able to self-limit the effectiveness of its strategy in order to configure an affordable level of difficulty, so that the human player still enjoys the game and does not throw in the towel too soon. These two kinds of chess machines have slightly different objectives: either winning the game, or else having the human player learn how to play better and enjoy the learning process. Nevertheless, in each case the machine has a well determined purpose or function that defines it. What we do not expect from a chess machine of the first kind (i.e. designed to win) is that it chooses to lose the game... *It can fail to achieve its goal, but it cannot change its goal.* Of course, there can be algorithms with different levels of goal selection and prioritization. However, those *dynamic goal-selection algorithms* are in fact obeying higher-order goals (meta-goals) to select convenient sub-goals and strategies.

We think Turing himself acknowledged this *lack of freedom* was essential in his conception of a computational machine, even if implemented by humans performing calculations: “A man provided with paper, pencil, and rubber, and *subject to strict discipline*, is in effect a universal machine” [9] (our italics). Notably, it happened exactly in this way in the internal organization of Bletchley Park labor groups set up by Turing and others to decipher German codes during World War Two [5]. Being ‘subject to strict discipline’ means not questioning at all the rules and purposes of the procedure, i.e. the computation.

#### IV. DETERMINATION, INDETERMINATION, SELF-DETERMINATION

Mechanism in philosophy is the view that all beings, whether lifeless or alive, are like complicated machines. Mechanism is closely linked to determinism, since the scientific and technological revolution of the 17th century made some philosophers –Hume among them– believe that all phenomena could eventually be explained in terms of ‘mechanical laws’, i.e. natural laws governing the motion and collision of matter under the influence of physical forces. Modern mechanistic views of living beings, including humans, comprise mechanical *information processing* as an essential element of the ‘living machine’, for example in behaviorist stimulus-response theories. We distinguish three ways of relationship between mechanistic determination and the behavior of humans and computational machines.

1. **Hetero-determination.** The behavior is fully determined by the received stimuli and the computational or neurological processing these stimuli undergo to produce a response, according to more or less complex programs and evaluation systems.

2. **Indetermination.** This view complements the previous one by adding a certain degree of uncertainty. However, indeterminism does not add anything essentially different to the Humean conception of human nature. In fact, these two views, hetero-determination and indetermination, agree in their radical negation of human freedom.
3. **Self-determination.** In this position the previous two are rejected. If human freedom, in its usual sense, is not an illusion, then it is not true that human behavior is determined (even only statistically) just by the material aspects of the body and the phenomena that occur in it. On the contrary, being truly free means that human beings self-determine in their actions.

#### V. SUMMARY OF THE ARGUMENT

David Hume conceives reason as the slave of the passions, which implies that human reason has predetermined objectives it cannot question. On the other hand, an essential element of an algorithm running on a computational machine is its predefined purpose: an algorithm cannot question its purpose, because it would cease to be an algorithm. We have reached a critical point for the Humean-computational view of human beings, since self-determination is not an algorithmically programmable function: *purpose is the prerequisite of an algorithm, not its result.* Therefore, if self-determination is the true essence of human freedom, then human beings are neither Humean robots, nor algorithmic machines.

We have *not* demonstrated that human beings are truly free (self-determined). We have only demonstrated that *if* humans are free, *then* they cannot be algorithmic machines; *then* human intelligence cannot be properly defined as an algorithmic process; and *then* human behavior cannot be perfectly emulated by algorithmic robots. Whether we, in some uncertain future, can produce in our laboratories a kind of non-algorithmic robots that can be properly called free, and whether they still can be called ‘robots’, will be the subject of further research.

#### REFERENCES

- [1] Copeland, B.J. (2002). The Church-Turing Thesis. *The Stanford Encyclopedia of Philosophy* (Summer 2015 Edition), Edward N. Zalta (ed.). <http://plato.stanford.edu/archives/sum2015/entries/church-turing>.
- [2] Génova, G., Quintanilla Navarro, I. Are Human Beings Humean Robots? *J. Exp. & Theor. Art. Int.* 30(1):177–186, Jan 2018.
- [3] Génova, G., Quintanilla Navarro, I. Discovering the principle of finality in computational machines. *Found. of Science*. Online 13 Feb 2018.
- [4] Hill, R.K. (2015). What an algorithm is. *Phil. & Techn.* 29(1), 35–59.
- [5] Hinsley, F. H., Stripp, A., eds. (1993). *Codebreakers: The inside story of Bletchley Park*. Oxford: Oxford University Press.
- [6] Hume, D. (1739). *A Treatise of Human Nature*, II-iii-3. London: John Noon. Text available online at <http://www.gutenberg.org/ebooks/4705> and <http://www.davidhume.org/texts/thn.html>.
- [7] Knuth, D.E. (1997). *The art of computer programming (vol. 1): fundamental algorithms*. Redwood City: Addison Wesley.
- [8] Turing, A. (1936). On computable numbers, with an application to the Entscheidungsproblem, *Proceedings of the London Mathematical Society* 2(42):230–265.
- [9] Turing, A. (1948). Intelligent Machinery. *National Physical Laboratory Report*. (Facsimile at [http://www.AlanTuring.net/intelligent\\_machinery](http://www.AlanTuring.net/intelligent_machinery).)
- [10] Vardi, M. (2012). What is an algorithm? *Comm. of the ACM* 55(3):5–5.



# Bireducts with tolerance relations

1<sup>st</sup> M. José Benítez-Caballero

Department of Mathematics  
University of Cádiz  
Cádiz, Spain  
mariajose.benitez@uca.es

2<sup>nd</sup> Jesús Medina

Department of Mathematics  
University of Cádiz  
Cádiz, Spain  
jesus.medina@uca.es

3<sup>rd</sup> Eloísa Ramírez-Poussa

Department of Mathematics  
University of Cádiz  
Cádiz, Spain  
eloisa.medina@uca.es

4<sup>th</sup> Dominik Ślęzak

Institute of Informatics  
University of Warsaw  
Warsaw, Poland  
slezak@mimuw.edu.pl

**Abstract**—Reducing the number of attributes by preventing the occurrence of incompatibilities and eliminating existing noise in the original data is an important goal in different frameworks, such as in those focused on modelling and processing incomplete information in information systems. Bireducts were introduced in Rough Set Theory (RST) as one successful solution for achieving a balance between the elimination of attributes and the characterization of objects that the remaining attributes can still distinguish. This paper considers bireducts in a general framework in which attributes induce tolerance relations over the available objects. In order to compute the new reducts and bireducts a characterization based on a general discernibility function is given.

**Index Terms**—Attributes reduction, tolerance relations, discernibility function, information bireducts.

## I. INTRODUCTION

Two complementary approaches to treat imperfect knowledge are Fuzzy Set Theory (FST) introduced by Zadeh [11] and Rough Set Theory (RST) proposed by Pawlak [9]. In FST, the elements belong to a set considering a certain degree of truth. On the other hand, RST computes approximations of concepts from incomplete information.

One of the main goal is to reduce databases keeping the same information. To this end, the reducts, minimal subsets of attributes preserving the original information, were studied in [3], [6], [8].

In this paper, we also consider bireducts, which are an extension the notion of reduct, that is, a subset of attributes and a subset of objects that prevent the occurrence of incompatibilities and eliminating existing noise in the original data.

Throughout the paper, we work with information reducts and information bireducts, as well as with decision reducts and decision bireducts. We also take into consideration similarity and tolerance relations in order to provide a natural relationship of distance among the elements of the universe. In some cases, a tolerance relation can be more appropriate since, for instance, the transitivity constraints imposed by similarity relations may produce conflicts with user's specifications or the exclusive use of similarity relations may cause wrong modeling of vague information. The notions and results obtained considering this framework is deeply studied in [2].

Partially supported by the Spanish Science Ministry project TIN2016-76653-P.

## II. (BI)REDUCTS IN INFORMATION SYSTEM

In this section we are going to present the notions of reduct and bireduct of an information system. First of all, we recall the idea of tolerance relation.

If we consider an information system  $\mathbb{A} = (U, \mathcal{A})$ , a fuzzy tolerance relation family  $\{E_a: V_a \times V_a \rightarrow [0, 1] \mid a \in \mathcal{A}\}$  and a family of values  $\Delta = \{\delta_a \in [0, 1] \mid a \in \mathcal{A} \cup \{d\}\}$ , we can define, for each  $a \in \mathcal{A}$ , the relations  $T_{a, \delta_a}$  as:

$$T_{a, \delta_a} = \{(v, w) \in V_a \times V_a \mid \delta_a \leq E_a(v, w)\} \quad (1)$$

Note that each relation  $T_{a, \delta_a}$  is straightforwardly a tolerance relation. Moreover, in the general environment of an information system or decision system, each attribute can have different nature and so, different thresholds could be assumed for each attribute. For further information about tolerance relations see [7]. For some examples on how to employ tolerance relations in rough set mechanisms of attribute reduction see, e.g. [10].

Based on a family of tolerance relations  $\mathcal{E} = \{R_a \subseteq V_a \times V_a \mid a \in \mathcal{A}\}$ , the notion of discernibility is generalized as follows.

*Definition 1:* Given an information system  $\mathbb{A} = (U, \mathcal{A})$ , a subset  $B \subseteq \mathcal{A}$  and a tolerance relation family  $\mathcal{E} = \{R_a \subseteq V_a \times V_a \mid a \in \mathcal{A}\}$ , we say that objects  $x, y \in U$  are  $\mathcal{E}_B$ -similar if for all  $a \in B$  we have

$$(a(x), a(y)) \in R_a$$

Otherwise, we say that objects  $x, y \in U$  are  $\mathcal{E}_B$ -discordant, that is, if the following holds

$$\{a \in B \mid (a(x), a(y)) \notin R_a\} \neq \emptyset$$

In the following definition, we present the notion of  $\mathcal{E}$ -information reduct, the generalization of reduct considering tolerance relations.

*Definition 2:* The set  $B \subseteq \mathcal{A}$  is called  $\mathcal{E}$ -information reduct if  $B$  satisfies that every pair  $x, y \in U$ , which is  $\mathcal{E}$ -discordant, is also  $\mathcal{E}_B$ -discordant, and  $B$  is irreducible with respect to this property, that is, there is no  $C \subsetneq B$  such that all pairs  $x, y \in U$  are  $\mathcal{E}_C$ -discordant.

Analogously, we generalize the notion of information bireduct.

*Definition 3:* Let  $\mathbb{A} = (U, \mathcal{A})$  be an information system. The pair  $(X, B)$ , where  $X \subseteq U$  and  $B \subseteq \mathcal{A}$ , is called  $\mathcal{E}$ -information bireduct if and only if all pairs  $x, y \in X$  are  $\mathcal{E}_B$ -discordant and,  $B$  is irreducible and  $X$  is inextensible with respect to this property.

### III. (BI)REDUCT IN DECISION SYSTEM

In this section, we will present the notions and result needed in order to study the knowledge of a decision system. We generalize the notion of decision reduct. Throughout this section, we consider a decision system  $\mathbb{A} = (U, \mathcal{A} \cup d)$ , that is, a set of objects, a set of attributes and a decision attribute.

*Definition 4:* Let  $\mathbb{A} = (U, \mathcal{A} \cup d)$  a decision system. A subset  $B \subseteq \mathcal{A}$  is called  $\mathcal{E}$ -decision reduct if  $B$  satisfies that every  $x, y \in U$ , which is  $\mathcal{E}_d$ -discordant and  $\mathcal{E}$ -discordant, is also  $\mathcal{E}_B$ -discordant, and  $B$  is irreducible with respect to this property.

In order to compute the reducts, we are going to use the generalization of the unidimensional discernibility function.

*Definition 5:* The unidimensional  $\mathcal{E}$ -discernibility function of  $\mathbb{A}$ , is defined as the following conjunctive normal form (CNF):

$$\tau_{\mathbb{A}}^{\text{uni}} = \bigwedge \left\{ \bigvee \{a \in \mathcal{A} \mid (a(x), a(y)) \notin R_a\} \mid x, y \in U, \right. \\ \left. (d(x), d(y)) \notin R_d \right\}$$

where the elements of  $\mathcal{A}$  are the propositional symbols of the language.

The following result presents a mechanism to compute the reducts, using the reduced disjunctive normal form associated with the unidimensional  $\mathcal{E}$ -discernibility function.

*Theorem 1:* An arbitrary set  $B$ , where  $B \subseteq \mathcal{A}$ , is a  $\mathcal{E}$ -decision reduct of  $\mathbb{A}$  if and only if the cube  $\bigwedge_{b \in B} b$  is a cube in the RDNF of  $\tau_{\mathbb{A}}^{\text{uni}}$ .

Also, we can define the decision bireduct considering a tolerance relation.

*Definition 6:* A  $(\mathcal{E}, U)$ -decision bireduct is a pair  $(X, B)$ , where  $X \subseteq U$  and  $B \subseteq \mathcal{A}$ , and satisfy that all  $x \in X$  and  $y \in U$ , with  $(d(x), d(y)) \notin R_d$ , are  $\mathcal{E}_B$ -discordant and,  $B$  is irreducible and  $X$  is inextensible with respect to this property.

The following definition presents the conjunctive normal form with which the bidimensional  $\mathcal{E}$ -discernibility function is defined.

*Definition 7:* The conjunctive normal form

$$\tau_{\mathbb{A}}^{\text{bi}} = \bigwedge \left\{ x \vee y \vee \bigvee \{a \in \mathcal{A} \mid (a(x), a(y)) \notin R_a\} \mid x, y \in U, \right. \\ \left. x < y, (d(x), d(y)) \notin R_d \right\}$$

where the elements of  $U$  and  $\mathcal{A}$  are the propositional symbols of the language, is called the bidimensional  $\mathcal{E}$ -discernibility function of  $\mathbb{A}$ .

This bidimensional  $\mathcal{E}$ -discernibility function is used in order to characterize the computation of  $\mathcal{E}$ -decision bireducts.

*Theorem 2:* An arbitrary pair  $(X, B)$ , where  $X \subseteq U$  and  $B \subseteq \mathcal{A}$ , is a  $\mathcal{E}$ -decision bireduct if and only if the cube  $\bigwedge_{b \in B} b \wedge \bigwedge_{x \notin X} x$  is a cube in the RDNF of  $\tau_{\mathbb{A}}^{\text{bi}}$ .

### IV. CONCLUSIONS AND FUTURE WORK

We have considered tolerance relations in order to study the reducts and bireducts in the classical environment of RST. We have generalized the classical notion of discernibility function, from which we have characterized the reducts and bireducts in these environments.

The consideration of tolerance relations within this theory provides a great flexibility in different environments and the range of possible applications increase dramatically, for example, considering fuzzy tolerance relations with thresholds.

In the future, we will consider the theory developed throughout this paper in order to provide a new reduction method in fuzzy FCA. In addition, the (bi)reduction proposed for FCA will be compared with other reduction mechanisms, which reduce the size of the concept lattice considering similarities [1], [5].

Furthermore, we will extend our approach to obtain bireducts in fuzzy environments, such as in fuzzy rough sets [3], [4] and we will apply the theory developed in both theories to practical cases.

### REFERENCES

- [1] R. Bělohávek, J. Dvořák, and J. Outrata. Fast factorization by similarity in formal concept analysis of data with fuzzy attributes. *Journal of Computer and System Sciences*, 73(6):1012 – 1022, 2007.
- [2] M. J. Benítez-Caballero, J. Medina, E. Ramírez-Poussa, and D. Ślęzak. Bireducts with tolerance relations. *Information Sciences*, 435:26 – 39, 2018.
- [3] C. Cornelis, R. Jensen, G. Hurtado, and D. Ślęzak. Attribute selection with fuzzy decision reducts. *Information Sciences*, 180:209–224, 2010.
- [4] C. Cornelis, J. Medina, and N. Verbiest. Multi-adjoint fuzzy rough sets: Definition, properties and attribute selection. *International Journal of Approximate Reasoning*, 55:412–426, 2014.
- [5] A. Formica. Ontology-based concept similarity in formal concept analysis. *Information Sciences*, 176(18):2624–2641, 2006.
- [6] A. Janusz and D. Ślęzak. Rough set methods for attribute clustering and selection. *Applied Artificial Intelligence*, 28(3):220–242, 2014.
- [7] F. Klawonn. Should fuzzy equality and similarity satisfy transitivity? comments on the paper by m. de cock and e. kerre. *Fuzzy Sets and Systems*, 133(2):175 – 180, 2003.
- [8] J. Medina. Relating attribute reduction in formal, object-oriented and property-oriented concept lattices. *Computers & Mathematics with Applications*, 64(6):1992–2002, 2012.
- [9] Z. Pawlak. Rough sets. *International Journal of Computer and Information Science*, 11:341–356, 1982.
- [10] A. Skowron and J. Stepaniuk. Tolerance approximation spaces. *Fundamenta Informaticae*, 27(2-3):245–253, 1996.
- [11] L. Zadeh. Fuzzy sets. *Information and Control*, 8:338–353, 1965.

**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 6:  
MULTIMEDIA E IMÁGENES







# A software tool for categorizing violin student renditions by comparison\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Miguel Delgado, Waldo Fajardo, Miguel Molina-Solana  
*Department of Computer Science and Artificial Intelligence*  
*University of Granada*  
Granada, Spain  
mdelgado@decsai.ugr.es, {aragorn, miguelmolina}@ugr.es

**Abstract**—Music Education is a challenging domain for Artificial Intelligence because of the inherent complexity of music, an activity with no clear goals and no comprehensive set of well-defined methods for success. It involves complementary aspects from other disciplines such as psychology and acoustics; and it also requires creativity and eventually, some manual abilities. In this paper, we present an application of machine learning to the learning of music performance. Our devised system is able to discover the similarities and differences between a given performance and those from other musicians. Such a system would be of great value to music students when learning how to perform a certain piece of music.

**Index Terms**—

# Towards an Automated Composer of Popular Spanish Songs: Integrating a Music Generator and a Song Lyrics Generator

María Navarro-Cáceres

*Computer Sciences Department CISUC, Department of Informatics Engineering*  
*University of Salamanca*  
Salamanca, Spain  
maria90@usal.es

Hugo Gonçalo Oliveira

*University of Coimbra*  
Coimbra, Portugal  
hroliv@dei.uc.pt

Juan M. Corchado

*University of Salamanca*  
Salamanca, Spain  
corchado@usal.es

**Abstract**—We describe the integration of two creative systems in what can be seen as an automated composer for Spanish popular music. We first present a system that generates melodies with a Markov Model learned from a corpus of Spanish popular music. Then, given the importance of the lyrics in this context, the latter was integrated with an existing lyrics generation system, adapted to suit this purpose. Several experiments were carried out to evaluate the quality of the results. Overall, melodies transmit a feeling of Spanish popular music, while the text of the lyrics is acceptable for a first approach.

**Index Terms**—Computational Creativity, Music Generation, Lyrics Generation

## I. INTRODUCTION

We can say that, today, Computational Creativity [1] is an established subfield of Artificial Intelligence. One that has attracted researchers with multiple origins and motivations, and where a variety of intelligent systems has been developed for the generation of a wide range of artifacts with a creative value, such as music [2], [3] or poetry [4], [5].

However, few creative systems have tackled both the previous at the same time, towards the production of music with lyrics. The main contributions of this work is the development of an automated composer, in this case focused on popular Spanish songs. It is based on the integration of two systems: ETHNO-MUSIC, a new system for generating popular melodies; and Tra-la-Lyrics [6], longer-established, which generates lyrics for a given rhythm. This is in line with recent collaborations between different creative systems (e.g., [7], [8]) and shows that, with the current landscape of creative systems, it is not always necessary to develop new systems from scratch.

On the specifics of the new system, most initiatives on music generation have focused on music with a rather tonal character and, to date, there has been no study addressing the generation of Spanish popular music. This genre differs from classical music in many aspects,

including the sonority (meaning the tonality of the music), the sound disposition or the rhythmic formulas used. The automatic generation of this kind of music also depends on multiple factors that are intrinsically connected, such as the representation of the tonality, the melodies and the rhythm. Moreover, unlike classical music, Spanish popular music is always linked to a functionality. In this sense, lyrics are essential for identifying the purpose for which the music was conceived, i.e. if it is a work song or a love song.

Drawing on this phenomenon, new melodies are generated, based on original Spanish popular songs in multiple sources of popular music. Musical excerpts were then analyzed and their relevant features were encoded and stored to be used as the training corpus for music. Among the different learning models that have been applied to generate music from a corpus, Markov Models (MM) were selected due to their successful application in related works [2], [3], [9].

Generation of lyrics starts once the melody is ready. Simple heuristics are applied for splitting the melody into parts, and then lines of text are generated for each part, while trying to maximize two main constraints: (i) one syllable per note; (ii) stressed syllables matching strong beats of the melody. The current version of Tra-la-Lyrics is built on top of PoeTryMe [5], a platform for poetry generation in different languages. In this case, generation is based on the Spanish instantiation, though with an augmented semantic network and new line templates, acquired automatically from songs in Spanish. In order to set the generation domain and establish a connection between lyrics and the subjects typically addressed in Spanish popular songs, seed words were carefully selected.

In the end, the resulting process is analogous to having two different people composing a song: one that composes the melody and another the lyrics. In this case, the melody is composed first, unlike other creative systems,



which generate music for given lyrics (e.g. [10], [11]). Given that the composition of a song by humans may follow a different order – starting with the lyrics vs starting with the melody –, we believe that it makes sense to tackle this challenge both ways.

Out of the compositions resulting from our integration, some were selected for human validation. Overall, the most positive aspects were that melodies were pleasant and had a sound and rhythm that gave a feeling of the Spanish popular songs, and that the text of the lyrics was within the target domains. Less positive aspects, but still average, were the rhythm and meaning of the lyrics. In the remainder of this paper, the integration effort is described with more detail and illustrative examples of generated songs are presented and discussed, together with the validation results.

## II. INTEGRATION

The generation of popular Spanish songs results from the integration of two creative systems: ETHNO-MUSIC, in charge of generating melodies, and Tra-la-Lyrics [6], in charge of lyrics generation. Figure 1 gives an overview of the resulting generation flow.

ETHNO-MUSIC is provided with a memory to store beforehand different melodies. It takes the melodies stored and trains a model for generating a new composition. For the purposes of this paper, Markov Models (MM) were used as the learning algorithm. Once the melody is available, Tra-la-Lyrics is used for generating lyrics that suit the melody.

### A. Music Generation

In the current work, music is generated based on the features of Spanish popular music, which include the rhythm or the sonority.

1) *Music Retrieval*: To generate melodies following the popular song standards, MMs are applied. They need a set of musical sources for the learning process, which should reflect the most common sonorities of the Spanish popular music. Therefore, the melodies are extracted from specialized songbooks, recordings and digital scores.

According to ethnomusicologists [12], three main factors should be considered in Spanish popular music: melodic behavior, rhythm and style. Regarding the melody, the modal music in Spain can follow seven diatonic modes (Jonic, Dorian, Phrigian, Lydian, Mixolydian, Eolian and Locrian). The melodic behavior consists of continuous chromaticizations and instabilities. In addition, melodies do not follow any predetermined scheme in terms of tonic and dominant functionalities, as they are based on modal paradigms. Popular music also contains a very uniform beat due to the syllabic text used in these songs, because the prose in this type of repertoire has a regular rhythmic nature, thus totally avoiding a prosodic rhythm. Finally, one of the key aspects of popular music

is their style, based on functionality, namely the context in which the music has been conceived. In this sense, we can classify music in different genres, each one representing their own musical features, such as sonority, lyrics and rhythm. Consequently, popular music could be classified accordingly as work songs, love songs, lullabies, wedding songs, sacred songs, dance music, and others.

Despite the general features shared by most popular songs, there was a series of musical parameters (i.e. rhythms or sonorities) spread throughout the Iberian peninsula that, over time, became different in each region or even disappeared in some. According to some authors [13], in Spanish popular music, the work, love songs and lullabies share features related to the key signature, rhythmic patterns and general sonority or tonality, which made them very interesting to use as a corpus in the development of the learning model. Therefore, in order to train the MM, melodies related to these genres that shared some common features were collected.

2) *Encoding Melodies*: To represent the information needed for the training of the MM, sources were digitalized. To identify popular music, we did not only analyze the particular duration or pitch, but also the duration of the musical phrases, the degrees in which the melody reposes (notes with a long duration), and the particular cadences. Drawing on these properties and also inspired by a concept of viewpoints [14], Table I shows the features encoded for training the MM.

TABLE I  
MUSICAL FEATURES ENCODED IN THE SONGS AND USED IN THE TRAINING OF THE MM.

Feature	Description
Pitch	MIDI number that corresponds to the musical note
Duration	Number that represents the rhythmic formula or one note. Each number can represent a whole, a half, a quarter, etc.
Degree	Number from 1 to 7 that represents the degree of each note according to the scale — 1 means the first degree, 7 means the last note in the scale
First in bar	Boolean number, where 1 represents the first note in a bar, otherwise it is 0
Time Signature	Represented by two numbers, one for the numerator and another for the denominator
Musical phrase	Represents the position of a note in a musical phrase, and can take three possible values: 1 if the note is the first in the phrase, -1 if it is the last one, and 0 otherwise

Currently, many songs are already encoded as MIDI (Musical Instrument Digital Interface) [15]. This is due to the availability of this format throughout the Web, the low difficulty in creating such files based on digital scores, and their structure, which allows a relatively easy access to musical features. Although XML or other encodings like MusicXML or MEI are also available and also encode musical features, we selected MIDI because



Fig. 1. Overview of music generation flow.

it is the format which most appears in the web, and which can be listened in almost every device. MIDI files include instructions that allow the reconstruction of the song by a sequencer and a synthesizer that works with MIDI specifications.

MIDIs provide information on musical events like pitch, duration and time signature, extracted for the purposes of this work. Yet, other, such as phrase construction, main sonority, melodic degree (position that a note takes in the scale) and bars, have to be manually added. This information has been encoded by following the codification proposed by [16], which use numbers to describe some musical parameters. These data are finally stored in a CSV file.

3) *Generating the Melody*: Once the files are available, the necessary information about the music is extracted. The data previously analyzed and incorporated in the files are used as to train the learning model. First, a model is learned for representing the data, which may be used for generating music. Among the possible approaches, MMs are a widely used tool to model the temporal properties of various phenomena, from the structure of a text to economic fluctuations, as well as content generation applications, such as text or music generation. MMs are a specific case of Bayesian Networks, in which the probability of an event occurring (in this case, a note or silence with a certain duration) depends only on the  $N$ -previous events. In this particular case,  $N$  has been established empirically to 4.

The music composition system modeled tries to create only one melody with a specific rhythm. Therefore, a MM has been learned to generate the melody and the rhythm at the same time. Once trained, each next transition (i.e., each note) is iteratively calculated by applying the probabilities of the MM according to the previous stages. Finally, each note generated by the learning model is encoded in MIDI, to be used in a standard synthesizer.

## B. Lyrics Generation

Tra-la-Lyrics [6] generates text based on rhythm, and is currently built on top of PoeTryMe [5], a versatile poetry generation platform. Tra-la-Lyrics can thus be seen as instantiation of the latter. It that shares most of PoeTryMe constituents, including the line generation module, which produces semantically coherent lines, with the help of a semantic network, and a grammar with line templates. Therefore, Tra-la-Lyrics follows a generate-and-test strategy to generate lyrics with the music already created.

Yet, in addition, Tra-la-Lyrics has a parts analyzer, for splitting the melody in parts; a rhythm analyzer, for ex-

tracting the rhythm of the melody; and a generation strategy that considers the position of the stressed syllables. Briefly, lyrics are produced after splitting the melody in smaller parts and getting a representation of the rhythm as a sequence of strong and weak beats. The generation strategy selects the best lines for each part, out of those generated by the line generation module.

1) *Parts Analyzer*: In PoeTryMe, a generation strategy selects and organizes lines, produced by the line generator, according to a given form. The end of a line is a suitable place for rhymes. For poems, the form is given by the number of stanzas, lines and target lengths. Given a melody, the limits of lines have to be identified automatically. We thus set simple heuristics for splitting melodies into parts, based on the lengths of the longest pause ( $LP$ ) and longest note ( $LN$ ): the melody is split after pauses that are  $LP/3$ -long or longer and notes that are  $LN/2$ -long or longer, if resulting parts have at least  $minP$  notes. Parts with more than  $maxP$  notes go through the same splitting process until they have less than  $maxP$  notes. The heuristics are similar to the LBDM algorithm for music segmentation [17], but only applied to rhythm, rather than pitch segmentation.

2) *Rhythm Analyzer*: The rhythm analyzer is the same as in the original version of Tra-la-Lyrics [18]. It is based on the dot system [19], which sets the metrical accents of each beat inside a bar, and thus the strengths of each note, according to their position. The first beat of each bar is always the strongest. Strengths are then distributed according to the beats (stronger) and downbeats (weaker), depending on the time signature. Tra-la-Lyrics only considers those that are substantially stronger, when compared to the remaining, as actual strong beats. For instance, in a 4/4, those will be the first and the third crotchets, and in a 3/4, only the first crotchet is used as the only strong beat.

3) *Generation Strategy*: Similarly to other instantiations of PoeTryMe, lines are selected with a generate-and-test approach. Briefly, for each line in the poem structure, textual fragments are retrieved from the line generation module. This strategy is responsible for selecting the fittest fragments for each line, from a maximum of  $n$  retrieved fragments per line. The fitness function is based on features that are relevant to the rhythm. It has penalties for: the difference between the number of syllables in a textual line and the number of notes in the musical part ( $\alpha$ ); unstressed syllables in strong beats ( $\beta$ ); stressed syllables in weak beats ( $\gamma$ ); and words interrupted by a pause ( $\delta$ ). In order to increase



the chance of rhymes, there is a bonus for each pair of nearby lines with the same termination ( $\epsilon$ ), unless they end with the same word, which results in another penalty ( $\zeta$ ).

4) *Line Generation*: PoeTryMe has line generation modules for producing text fragments in Portuguese, English and Spanish, with a semantic network and a grammar with templates, tightly connected with the relation types in the network. Towards generation within a semantic domain, the network is first constrained by a set of seed words. Line generation involves selecting a relation instance (e.g. computer usedFor work; guitar usedFor music; hat usedFor shade), and using its arguments for filling the placeholders of a suitable rule (e.g. usedFor  $\rightarrow$  *be my [arg1], i'll be your [arg2]*).

Given the kind of text to generate, it made sense to use the Spanish instantiation, though with some additions that enable the generation of more varied lines. In the Spanish adaptation, semantic relations covered mainly synonyms and hypernyms, while lines of the generation grammar had been extracted from an anthology of about 400 Spanish poems. For this work, the semantic network was enriched with relations between two Spanish words in the most recent version of ConceptNet [20]. Moreover, for the creation of the grammar, a set of about 9,000 Spanish song lyrics, retrieved from the MusixMatch database<sup>1</sup> was also exploited. To complete the adaptation, lyrics had to be generated with seed words related to concepts typically invoked in Spanish popular lyrics.

### III. RESULTS

The integration of ETHNO-MUSIC and Tra-la-lyrics results in a new system for the generation of songs, covering melody and lyrics. Here, we describe the settings used towards the generation of several Spanish popular songs and discusses some generated examples.

#### A. Music Generation Settings

For the generation of the music, 102 popular songs were selected, namely 68 work songs and 34 love songs, all using similar rhythm patterns, with a time signature of 3/4. Each song consisted of 3 or 4 musical phrases with similar length, with the same sonority, the Phrygian mode with possible modifications in its evolution to E minor.

Melodies were encoded as described earlier and saved in a CSV file. Their features were the corpus for training the MM. The number of states that it can remember for the future generation of the melody was empirically set to 4. During the generation process, each iteration of the MM consists of adding a new note to the melody. The MM is iterated until four musical phrases have been created.

For the experiments, a total of 40 melodies were generated with ETHNO-MUSIC, out of which five we were happy with were selected for lyrics generation by Tra-la-lyrics.

<sup>1</sup><https://www.musixmatch.com>

#### B. Lyrics Generation Settings

In order to split the melody in parts, we empirically set  $minP = 4$  and  $maxP = 18$ . For each of the five melodies, lyrics were generated with groups of seed words that set two generation domains, common in Spanish popular songs:

- Work in the fields: *trabajo, siega, tierra, sembrar, semillas, trigo, cereales, campo, sol, paja, cosecha, cosechar* (in English, work, harvest, land, sow, seeds, wheat, cereals, field, sun, straw, harvest, harvest)
- Love: *amor, novia, moza, mozo, bella, belleza, feliz, alcoba, morena, guapa, sonrisa, ojos, bonito, bonita* (in English, love, girlfriend, girl, lad, beautiful, beauty, happy, bedroom, brunette, pretty, smile, eyes, pretty)

For each melody-domain pair, 10 lyrics were generated. Though, out of each 10, only the one with the best rhythm-based score, computed automatically, was selected for human validation, which makes a total of 10 songs.

For each line, we empirically set the number of generations  $n = 1,750$ . In order to match the target rhythm, the parameters of the fitness function were:  $\alpha = 1$ ,  $\beta = 0.5$ ,  $\gamma = 0.1$ ,  $\delta = 0.3$ ,  $\epsilon = 2$ ,  $\zeta = 1$ .

#### C. Examples

Figures 2 and 3 show examples of two generated songs, selected from the validation sample. For each example, we present the score, the Spanish lyrics assigned to the corresponding notes, and a rough English translation of their text. All the melodies generated share representative features of popular music, such as the constant repetition of pitches and the limited tessitura. Additionally, to some extent, lyrics match the rhythm and use a varied range of words related to the selected topics.

In the melody of figure 2, the limited tessitura is clear as the notes go from E to B. The rhythmic formulas are very repetitive and centered on the syllabic text that accompanies the melody, instead of showing complex rhythm figures. The melody rests on the E note and the third degree, which is typical of modal music, unlike tonal, where rests are preferred in the fifth or tonic degrees. Lyrics for this song were generated with the work-related seeds, which is clear by the presence of words like *trabajo* (work) or *campo* (field), from the seed set, and also other related words, such as *recoger* (to collect, related to harvest). On the rhythm, a minority of unstressed syllables is on strong beats, namely the first syllable of *fin-gi-dos* and the last of *en-tor-no*, but this is somehow compensated by the presence of two rhymes, *nidos/fingidos* and *color/mejor*.

In the melody of figure 3, besides the repetitive rhythm, there are musical rests, another desired feature. The use of short musical phrases is very typical in Spanish popular songs because they are thought for short lyrical phrases that people can remember. Lyrics for this song were generated with the love-related seeds, which results in the presence of words like *amor* and *mozo*, both

re - co - ger con - mi - go es - ta no - che pa - ra reu - nir ni - dos y fal - tan es - ta - dos  
 y so - bran ni - ve - les fin - gi - dos tra - ba - jo - sa tra - ba - jo co - - lor a - ra  
 ñán - do - le al en - tor - - no el cam - po me - jor

Take with me this night to join nests  
 We run out of terraces and exceed pretended levels  
 Hard color working scratching the better field

Fig. 2. Song in Phrigian mode, with Spanish lyrics on the domain 'trabajo' (work), including rough English translation.

in the seed set, and indirectly related words such as *maravillosa* (wonderful, related to pretty) or *barbilla* (chin, a part of the face, as the eyes). On the rhythm, we identify two unstressed syllables in strong beats, namely the first syllable of *bar-bi-lla* and the first of *al-guien*. This is again compensated by the presence of two rhymes, *vulgaridad/enfermedad*, *amor/interior*.

bus - cas tu a - pa - rien - cia en for - ma de vul - ga - ri - dad por u - na ma - ra - vi - llo - sa y cau - ti - va  
 do - ra en - fer - me - dad bar - bi - lla y faz mi dul - ce a - mor  
 al - guien e - - fe - bo la lla - ve de mi mo - zo in - terior

You look your appearance in the shape of vulgarity  
 because of a wonderful and irresistible disease  
 Your chin and face, my sweet love  
 somebody stole the key of my heart

Fig. 3. Song in Phrigian mode, with Spanish lyrics on the domain 'amor' (love), including rough English translation.

#### IV. VALIDATION

Once designed and implemented, we got insights on the validity of the new automated composer. Due to the inherent subjectivity of human listeners, this kind of evaluation remains a challenge for music composed automatically [21]. The same happens for creative text. Following other examples of subjective evaluation by a group of human listeners (e.g. [22]–[24]), who perform listening tests, we follow a similar approach for evaluating the musical results and the lyrics of the system.

More precisely, ten generated songs (five melodies with two lyrics for each) played with a MIDI synthesizer and shown in a score with the notes and the lyrics, were presented to 7 users, experts in popular music. For each song, we asked their opinion on the musical aspects, the text of the lyrics and on their connection, with the following questions, to be rated with a 5-point Likert-scale, between 1 (poorly) and 5 (perfectly well):

- 1) Melody: How pleasant is the melody?

- 2) Sound: How well does the melody, in some way, give a feeling of the popular style of the songs?
- 3) Rhythm of the Melody: How well does the rhythm suit the popular music style?
- 4) Rhythm of the Lyrics: How well does the text suit the rhythm of the original melody?
- 5) Subject: How is the text related to any of the following topics: work, love?
- 6) Meaning: How much sense does the text of the lyrics make? Is it possible to, somehow, interpret it?
- 7) Overall quality: In general, what is the quality of the melody plus lyrics?

Some of the questions involve an appreciation of music and text as a whole (Rhythm of the lyrics, Overall) and others are more focused on only one of the previous. Yet, although each of the systems had been somehow validated on their own, having both music and lyrics may influence the way that the results are perceived by humans. Plus, this instantiation of PoeTryMe/Tra-la-Lyrics has significant differences from previous (e.g., music is automatically split in parts, lyrics are generated in Spanish, text of Spanish lyrics was exploited, as well as ConceptNet for additional knowledge).

We expect the system to reflect the perceptual quality of the melodies according to the popular songs style. Likewise, we wanted to verify the quality of the lyrics according to the positive ratings given by the listeners. Table II presents the mode ( $M_o$ ) and median ( $M_d$ ) ratings for each assessed item.

TABLE II  
 OVERALL VALIDATION RESULTS FOR THE 10 ASSESSED SONGS.

Item	Rating					$M_o$	$M_d$
	1	2	3	4	5		
Melody	0	3	21	36	10	4	4
Sound	1	4	22	39	4	4	4
Rhythm (Melody)	2	9	23	34	2	4	4
Rhythm (Lyrics)	3	13	27	25	1	3	3
Subject	2	12	23	25	8	4	3
Text Meaning	7	17	28	15	3	3	3
Overall Quality	3	5	36	24	2	3	3

For every assessed item, the majority of the ratings falls in 3 or 4. Yet, the proportion of 4s is higher for the melody-related aspects than for the text-related, where the proportion of 3s is higher. This suggests that the melody is pleasant, and the sound follows quite well the standards of Spanish popular music, as does the rhythm. The worst scoring item is text meaning, which shows that generating text on a topic is only halfway for generating a meaningful test. On the other hand, the quality of the lyrics is lower, but still average. The overall quality of music and lyrics is also average.

#### V. CONCLUSION

We described the effort and results of integrating a music and a lyrics generator towards the development of an intelligent system that creates popular Spanish songs with lyrics, automatically. The music generator is



based on a MM, trained on features extracted from a corpus of Spanish popular music. The lyrics generator produces textual fragments that match a given rhythm, with syntactic coherence handled by a grammar and semantics controlled by the combination of the previous grammar with a semantic network.

We see this as a successful effort, because the resulting system generates melodies that follow the Spanish songs standards, with Spanish lyrics on topics typically covered by the popular songs. This is confirmed by a human evaluation which also revealed that the less positive aspects, though still average, are the rhythm of the lyrics and, especially, their meaning.

Besides the success of integrating two different systems developed independently, given that this was our first approach to our goal, we can say that we are happy with our results. Yet, during this work, we identified limitations, some with the help of the human validation, to be addressed in the future, for a new version of the composer.

Regarding the lyrics, despite the utilization of a mature system for generation, alternative strategies could be tested for matching the rhythm. Although the instantiations of PoeTryMe often use a generate-and-test approach, an evolutionary strategy, available in the same platform, could make more sense for lyrics, where the fitness function has more parameters. Generating meaningful lyrics is always a challenging task and we are aware of the limitations of PoeTryMe on this topic. We will investigate this issue further. Yet, natural improvements would be using a larger corpus for extracting the grammars or, for the specific case of this work, use a corpus of lyrics of Spanish popular songs, which we still could not find. Given the importance of lyrics in popular music for ethnomusicologist studies, a deeper analysis of popular songs and their lyrics should be addressed towards the generation of better lyrics of this kind.

An improvement on the integration process would be to have the music generation system providing the division of musical parts directly to the lyrics generation system, together with the melody. This would possibly avoid the heuristics currently applied for this purpose. In order to improve the automatic generation of music, more features of melodies could be used, including a more general view of the composition. It would also be interesting to test singing voice synthesis software for singing the generated songs, which could possibly make the validation clearer.

#### ACKNOWLEDGEMENTS

This work was supported by the Spanish Ministry of Economy and FEDER funds. Project. SURF: Intelligent System for integrated and sustainable management of urban fleets TIN2015-65515-C4-3-R.

#### REFERENCES

- [1] S. Colton and G. A. Wiggins, "Computational creativity: The final frontier?" in *Frontiers in Artificial Intelligence and Applications*, vol. 242, 2012, pp. 21–26.
- [2] F. Pachet and P. Roy, "Markov constraints: steerable generation of Markov sequences," *Constraints*, vol. 16, no. 2, pp. 148–172, 2011.
- [3] A. Papadopoulos, P. Roy, and F. Pachet, "Assisted Lead Sheet Composition Using FlowComposer," in *International Conference on Principles and Practice of Constraint Programming*. Springer, 2016, pp. 769–785.
- [4] P. Gervás, "WASP: Evaluation of different strategies for the automatic generation of spanish verse," in *Proceedings of AISB'00 Symposium on Creative & Cultural Aspects and Applications of AI & Cognitive Science*, Birmingham, UK, 2000, pp. 93–100.
- [5] H. Gonalo Oliveira, R. Hervás, A. Díaz, and P. Gervás, "Multilingual extension and evaluation of a poetry generator," *Natural Language Engineering*, vol. 23, no. 6, pp. 929–967, 2017. [Online]. Available: <https://doi.org/10.1017/S1351324917000171>
- [6] H. Gonalo Oliveira, "Tra-la-lyrics 2.0: Automatic generation of song lyrics on a semantic domain," *Journal of Artificial General Intelligence*, vol. 6, no. 1, pp. 87–110, December 2015, special Issue: Computational Creativity, Concept Invention, and General Intelligence.
- [7] M. Znidarsic, A. Cardoso, P. Gervás, P. Martins, R. Hervás, A. O. Alves, H. Gonalo Oliveira, P. Xiao, S. Linkola, H. Toivonen, J. Kranjc, and N. Lavrac, "Computational creativity infrastructure for online software composition: A conceptual blending use case," in *Proceedings of the 7th International Conference on Computational Creativity*, ser. ICCO 2016, 2016, pp. 371–379.
- [8] E. Concepción, P. Gervás, and G. Méndez, "A collaborative architectural model for automatic story generation," in *Proceedings of the 5th AISB Symposium on Computational Creativity*, University of Liverpool, UK, 2018.
- [9] R. P. Whorley and D. Conklin, "Music generation from statistical models of harmony," *Journal of New Music Research*, vol. 45, no. 2, pp. 160–183, 2016.
- [10] J. M. Toivanen, H. Toivonen, and A. Valitutti, "Automatic composition of lyrical songs," in *Proceedings of 4th International Conference on Computational Creativity*, ser. ICCO 2013. Sydney, Australia: The University of Sydney, June 2013, pp. 87–91. [Online]. Available: <http://www.computationalcreativity.net/iccc2013/download/iccc2013-toivanen-toivonen-valitutti.pdf>
- [11] M. Ackerman and D. Loker, "Algorithmic songwriting with ALYSIA," in *Computational Intelligence in Music, Sound, Art and Design - 6th International Conference, EvoMUSART 2017, Amsterdam, The Netherlands, April 19-21, 2017, Proceedings*, 2017, pp. 1–16. [Online]. Available: [https://doi.org/10.1007/978-3-319-55750-2\\_1](https://doi.org/10.1007/978-3-319-55750-2_1)
- [12] M. Manzano Alonso, "Cancionero popular de burgos," *Dip. de Burgos*, 2001.
- [13] K. Schindler, *Música y poesía popular de España y Portugal*. Centro de Cultura Tradicional, 1991.
- [14] R. P. Whorley, G. A. Wiggins, C. Rhodes, and M. T. Pearce, "Multiple viewpoint systems: Time complexity and the construction of domains for complex musical viewpoints in the harmonization problem," *Journal of New Music Research*, vol. 42, no. 3, pp. 237–266, 2013.
- [15] S. Jungleib, *General Midi*. AR Editions, Inc., 1996.
- [16] D. Conklin and C. Anagnostopoulou, "Representation and discovery of multiple viewpoint patterns," in *ICMC*. Citeseer, 2001.
- [17] E. Cambouropoulos, "The local boundary detection model (lbdm) and its application in the study of expressive timing," in *ICMC*, 2001.
- [18] H. R. Gonalo Oliveira, F. A. Cardoso, and F. C. Pereira, "Tra-la-Lyrics: an approach to generate text based on rhythm," in *Proceedings of the 4th International Joint Workshop on Computational Creativity*. London, UK: IJWCC 2007, June 2007, pp. 47–55.
- [19] F. Lerdahl and R. Jackendoff, *A generative theory of tonal music*. Cambridge, MA: The MIT Press, 1983.
- [20] R. Speer, J. Chin, and C. Havasi, "Conceptnet 5.5: An open multilingual graph of general knowledge," in *Proceedings of 31st AAAI Conference on Artificial Intelligence*, San Francisco, California, USA, 2017, pp. 4444–4451.



- [21] M. Pearce, D. Meredith, and G. Wiggins, "Motivations and methodologies for automation of the compositional process," *Musicae Scientiae*, vol. 6, no. 2, pp. 119–147, 2002.
- [22] M. Delgado, W. Fajardo, and M. Molina-Solana, "Inmamusys: Intelligent multiagent music system," *Expert Systems with Applications*, vol. 36, no. 3, pp. 4574–4580, 2009.
- [23] M. T. Pearce and G. A. Wiggins, "Evaluating cognitive models of musical composition," in *Proceedings of the 4th international joint workshop on computational creativity*. Goldsmiths, University of London, 2007, pp. 73–80.
- [24] T. Collins, R. Laney, A. Willis, and P. H. Garthwaite, "Developing and evaluating computational models of musical style," *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, vol. 30, no. 1, pp. 16–43, 2016.



# Goal-Reasoning in StarCraft: Brood War through Multilevel Planning

Moisés Martínez  
King's College London  
London, United Kingdom  
moises.martinez@kcl.ac.uk

Nerea Luis  
Universidad Carlos III de Madrid  
Leganes, Spain  
nluis@inf.uc3m.es

**Abstract**—Real-Time Strategy video-games (RTSVGs) are challenging for most deliberative approaches, such as Automated Planning. This is due to (i) the dynamic changes of the environment; (ii) and the wide variety of potential actions that can be performed over the environment. The aim is “to win the match”. Besides, RTSVGs presents an additional challenge: managing goals during the game is extremely hard. They change as the game state evolves either because of actions performed by the different agents (player and opponents), by new available information or by unexpected changes of the environment. Thus, generating a detailed sequence of actions –plan– to win the match is not effective in the long term.

In this paper, we propose an autonomous approach based on two levels of declarative Automated Planning. They are included inside a planning and execution architecture. The high-level, macromanagement, searches and suggests a set of soft-goals according to the current state and the available features of the agent. The low level, micromanagement, generates short plans of actions to reach the soft-goals generated by the high level. We claim that the ability of self-generating goals improves the plan generation and execution performance in a dynamic environment. Finally, we present a preliminary empirical evaluation of this approach tested on StarCraft: Brood War.

**Index Terms**—Automated Planning, Goal-Reasoning, Planning and Execution, Cognitive Systems, Video-Games

## I. INTRODUCTION

In recent years, video-games have gotten attraction by the Artificial Intelligence (AI) research community, as they offer challenging environments to test different AI techniques. Specially, StarCraft, which has become popular due to competitions such as SCAAIT<sup>1</sup>, AIIDE<sup>2</sup> and the CIG Competition<sup>3</sup>. These competitions provide APIs and tools to easily deploy different AI approaches into StarCraft.

RTSVGs are considered a sub-genre of strategy games e.g. chess, backgammon, go, monopoly, etc. in which players develop a settlement based into two principles: (i) an economy i.e. exploitation of natural resources to build throughout the environment; (ii) and a military power i.e training different units and researching technologies which offer advantages over the enemy. These features hinder the application of traditional AI approaches i.e. the game complexity is extremely large in terms of the size of the state space and the search space and in

the number of actions that can be executed on each decision step. For instance, a StarCraft map is defined as a rectangular grid where each tile is measured in building tiles. The smallest map has 64 x 64 building tiles. Thus, if a player builds the barracks (3x4), there exist 4096 tiles where they can be built in the worst case. If the player has four workers, there are 16384 instantiated actions available. Besides, a StarCraft match is executed at 24 frames per second, which means that the game state changes every 42 ms. The environment is non fully-observable, players just know the part of the environment that has been previously explored or built. In addition, the StarCraft environment is continuous, which means that players' turns do not explicitly exist. Actions are executed when requested by the players. Some actions can be executed in parallel. Besides, actions in this kind of games are durative. Thus, there is a small delay after the player chooses the action until it is executed on the game.

In order to win a match in a RTSVG like StarCraft, we must generate and execute a sequence of repetitive actions (plan) to defeat the opponent. But, to achieve this final goal, we must achieve first a huge number of small goals which appear during the game based on our previous actions and the new information discovered. Automated Planning (AP) is able to generate a sequence of actions that solves a specific problem like this one. Goals are usually given as input or as a part of the problem representation. However, in complex environments such as StarCraft, it is not possible to initially define a set of goals due to two important reasons: (i) the dynamism of the environment; (ii) the capabilities of the player, improved or penalized according to the actions executed over the environment. Nonetheless, several approaches based on AP have been successfully used before to solve complex problems with partial information such as the planning Mars exploration missions [1], managing fire extinctions [5], controlling underwater vehicles [20], intermodal transportation problems [8] and controlling quadcopters [3]. The key was to include some specific knowledge that simplified the deliberative act of reasoning.

In this paper, we propose a two level planning architecture. The high level consists on a goal-reasoning process, which generates goals based on the available information from the match e.g. player, environment, opponent etc. The low level consists on a deliberative process, which generates small plans

<sup>1</sup><http://sscaitournament.com/>

<sup>2</sup><http://www.cs.mun.ca/~dchurchill/starcraftaicom/>

<sup>3</sup><https://sites.google.com/site/starcraftaic/>

that should reach the goals suggested by the higher level. These two levels are included into a goal-reasoning, planning and execution loop, which helps to control and process the real situation of the game to quickly update the plans.

This paper is organized as follows: first in Section II, we describe the planning framework. Then, Section III presents a description of the application domain. Section IV describes our contribution: the goal-reasoning process to control a StarCraft player. Later on Section V, we show preliminary experiments of our approach in different maps. Section VI contains the related work. Finally, in Section VII we present some conclusions and future work directions.

## II. PLANNING FRAMEWORK

In this section, we describe the different planning formalisms that define the Multilevel Planning approach. It considers two different kind of planning tasks: (i) a sequential classical planning task, which is encoded in the propositional fragment of the standard Planning Domain Description Language (PDDL) 2.2 [6]; and (ii) a temporal planning task, which is encoded in the propositional fragment of the standard in PDDL 2.1 [7]. In PDDL, a planning task is described in terms of objects of the world (units, buildings, mineral, etc), predicates which describe static or dynamic features of these objects (e.g. building are locations in a specific position), actions (a unit can move from one location to another, an unit can be training in a building), an initial state that describes the initial situation, and a goal definition which describes the objectives that must be reached (goals).

**Definition 1: (Planning task).** A planning task can be defined as a tuple  $\Pi = (F, A, I, G)$ , where:

- $F$  is a finite set of grounded literals (also known as facts or atoms).
- $A$  is a finite set of grounded actions derived from the action schemes of the domain.
- $I \subseteq F$  is a finite set of grounded predicates that are true in the initial state.
- $G \subseteq F$  is a finite set of goals.

Any state  $s$  is a subset of facts that are true at a given time step. Each action  $a_i \in A$  can be defined as a tuple  $a_i = (Pre, Add, Del)$ , where  $Pre(a_i) \subseteq F$  are the preconditions of the action,  $Add(a_i) \subseteq F$  are its add effects, and  $Del(a_i) \subseteq F$  are the delete effects.  $Eff(a) = Add(a) \cup Del(a)$  are the effects of the action. Actions can also have a cost,  $c(a)$  (the default cost is one). An action  $a$  is applicable in  $s_i$ , if  $Pre(a) \subseteq s_i$ . The result of applying  $a$  in a state  $s_i$  generates a new state that can be defined as:  $s_{i+1} = (s_i \cup Add(a) \setminus Del(a))$ . A plan  $\pi$  is an ordered set of actions (commonly, a sequence)  $\pi = (a_1, \dots, a_n), \forall a_i \in A$ , that transforms the initial state  $I$  into a state  $s_n$  where  $G \subseteq s_n$ . This plan  $\pi$  is valid if the preconditions of each action are satisfied in the state where the corresponding action is applied; i.e.  $\forall a_i \in \pi, Pre(a_i) \subseteq s_{i-1}$  such that from applying the action  $a_i$  in the state  $s_{i-1}$  the system transits to  $s_i$ . The state  $s_0$  represents  $I$ .

**Definition 2: (Temporal Planning task).** A temporal planning task is a tuple  $\Pi = (F, A^d, I, G)$  where

- $F$  is a finite set of grounded literals (also known as facts or atoms) and numerical functions.
- $A^d$  is a finite set of grounded durative actions.
- $I \subseteq F$  is a finite set of grounded predicates that are true in the initial state and a set of numerical functions.
- $G \subseteq F$  is a finite set of goals.

Each action  $a_i \in A^d$  can be defined as a tuple  $a_i = (D, Pre, Add, Del)$ , where  $D(a_i)$  is the duration of the action  $a$ .  $Pre(a_i) = \langle Pre_s(a_i), Pre_o(a_i), Pre_e(a_i) \rangle$  where  $Pre_s(a_i)$  are preconditions given at the start of  $a$ ;  $Pre_o(a_i)$  are preconditions given during the action's duration; and  $Pre_e(a_i)$  represents preconditions given at the end of  $a$ .  $Add(a_i) = \langle Add_s(a_i), Add_e(a_i) \rangle$ , where  $Add_s(a_i)$  are the add effects at the start of  $a_i$  and  $Add_e(a_i)$ , the ones at the end.  $Del(a_i) = \langle Del_s(a_i), Del_e(a_i) \rangle$ , where  $Del_s(a_i)$  are the delete effects at the start of  $a_i$  and  $Del_e(a_i)$ , the ones at the end.

## III. DESCRIPTION OF THE REAL TIME ENVIRONMENT

Our approach has been applied to StarCraft: Brood War <sup>4</sup>, which is a popular RTSVG that runs a science-fiction universe where three races (*Terran*, *Protoss* and *Zerg*) are at war. The aim is to defeat all your opponents. Players start the match in a random position of the map. During the match, the player exploits the resources in order to (i) train new workers; (ii) build new buildings - which allow players to train soldier units, unlock stronger units and unlock new buildings-; and (iii) research new technologies - improve units' features or unlock new skills-. Besides, the player has to explore the environment to discover new resources, expand its territory and find the opponents' position. In the end, players must define a global strategy in order to destroy every opponent's units and buildings.

Our definition of global strategy is composed by simple actions. First, actions related with units' control (e.g. collect, move, train, build, explore, research and attack) for micromanagement. Second, actions related with the global strategy (e.g. which kind of unit must be trained, which kind of building must be built, when and where to attack) for macromanagement. For instance, in order to build a tank we need first to build a *Machine shop*, a *Factory* and a *Command Center*. Thus, we need at least one worker to build the four buildings on four suitable locations in the map -that need to be explored first-. For instance, when the action "train a tank" is executed, a set of micromanagement actions were performed first. From the planning perspective, the macromanagement actions can be considered as dynamic soft-goals, which are generated during the match according to the information provided by the environment and the player; and the micromanagement actions are the sequence of actions of the plan  $\pi$  that reach the soft-goals. that

## IV. GOAL-REASONING THROUGH MULTILEVEL PLANNING

StarCraft is a RTSVG where two or more players must compete for the resources of the environment in order to win

<sup>4</sup><https://starcraft.com>



the match. From the point of view of planning, a StarCraft player should execute a sequence of actions – plan – provided by the planner to defeat all its opponents. However, generating a sequence of actions in a dynamic environment with partial information arises some issues: (i) new information about the environment is usually discovered during the action’s execution; (ii) actions must be quickly chosen to interact within the environment as fast as possible - the sooner it happens, the greater the similarity with the current planning state; and (iii) goals should be generated dynamically during the game because of the lack of information. As we described before, the main goal of StarCraft is to win the match. Thus, the first issue we faced is how to model the PDDL domain to reach this hard goal. We are certain that this could not be satisfied if we just used classical planners. As the goal *win the match* is an abstract goal, it cannot be reached from a specific action executed by player. Neither a group of actions executed sequentially or in parallel guarantees to win the match. As the environment changes fast, it makes useless any long-term plan.

Our approach solves this issue by having a process that generates soft goals. They could be easily reached (or might not) according to the state of the match. Also, the agent has “high-level” tasks such as move, build, train or attack. Those can work as soft-goals as long as there is some low-level process to handle them on the game.

In previous works, the goal-reasoning problem has been addressed from different directions: (i) using an independent goal-reasoning system which receives a model of the environment, the current state and at least an initial goal, and returns either the same goal or a new one [14]; (ii) learning a model by means of Machine Learning to predict which goals must be achieved in order to control a real-time system [18]; and (iii) performing a hard goal life-cycle composed of different steps (selection, expansion, commit, dispatch, and finally execution) [10], [21]. In this paper, we propose an autonomous approach based on multiple levels of planning [17] that encapsulates the complexity of the domain in different layers.

The multilevel planning system is composed by two levels (macro and micro) of planning. The macromanagement level (high level) employs an abstract representation of the environment (numerical and logical) in order to define the set of soft-goals. This level uses temporal planning, which provides a richer version of PDDL e.g durative-actions, numerical fluents in preconditions and preconditions, etc. The output plan is a parallel plan, which explicitly indicates when two actions can be executed in parallel. Additionally, the soft-goals generation allow to use different policies for the generation of the plan in the micromanagement level. Figure 1 shows an example of an action defined in temporal PDDL which generates a goal `build-building(?b, ?l)` where `b` is the type of the building and `l` is the technological level needed to build it. As a result, this action generates goals to build any kind of building except for *Refinery* and *Supply Depot* which have special properties.

The temporal planner needs three elements to work: (i) an

```
(:durative-action generate-build-building
:parameters (?b - building
             ?l - level
             ?a - area)
:duration (= ?duration
          (* (building_cost ?b)
            (number_buildings ?b ?a)))
:condition (and
            (at start (> (free_units scv) 0))
            (over all (> (max_number_goals) 0))
            (over all (tech_level ?l))
            (over all (tech_level_building ?b ?l))
            (over all (can_build ?b)))
:effect (and
        (at end (decrease (max_number_goals) 1))
        (at start (decrease (free_units scv) 1))
        (at end (increase (free_units scv) 1))
        (at end (have_building ?b ?a))
        (at end (increase (number_buildings ?b ?a) 1))
        (at end (increase (goals_score)
                          (score_building ?b))))))
```

Fig. 1. Example of a durative action that generates building goals.

initial state; (ii) a specific domain that accurately describes a set of actions that, when instantiated, will serve as goals to “guide” the low-level planner; and (iii) a set of goals in order to stop the search process when they are satisfied. We were inspired by the limited horizon search approaches [11], [13] to define the stop criteria, which in our case is the upper-bound of goals that can be generated. We defined a fluent called (*max-number-goals*) as a counter that decreases in one each time an action-goal is generated. It stops in zero. The sequence of actions generated by the temporal planner is transformed into goals, which are used by the low planning level. Each action of the plan is considered like a predicate which must be reached in the next level.

The micromanagement level (low level) uses a structured representation of the environment to reach the previous soft-goals. This level employs classical planning in order to reach the goals. The plan described in Figure 3 is transformed into a group of three goals: (1) train a worker (*SCV*) in a *Command Center*, (2) build *Barracks* and (3) build a *Supply Depot*. Each goal needs a sequence of detail actions to be reached. The training goal needs two actions: one to chose a building of type command center (if there are more than one) and start training process of a *SCV* unit. After that, each building goal needs four actions to be reached: one action to choose an available worker that will perform the building process, a second action that chooses an available location using a external search algorithm, a third action that moves the worker to the building location and finally a fourth action which starts the building process. The agent will interleave goal and plan generation in a infinite loop using the PELEA architecture<sup>5</sup>, which now implements the macro and micromanagement levels into its different modules. Therefore, in order to handle more complex situations we are using different planners working at

<sup>5</sup>The architecture described here is an instantiation of the original version [19] which employs two different representations of the environment in PDDL.

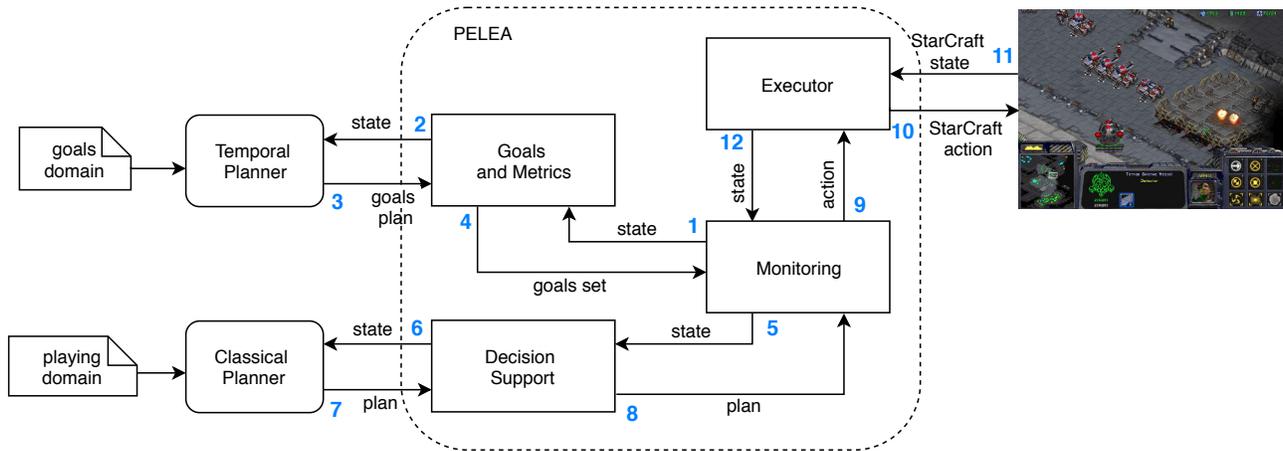


Fig. 2. Overview of the PELEA architecture applied to StarCraft. The multilevel planning approach is shown on the left of the Figure, where the temporal planner is in charge of generating the goal-based actions’ plan (macromanagement level) and the classical planner generates the sequence of game actions (*micromanagement* level). Numbers in blue indicate the flow of the architecture from the initial state of the game. First, *Monitoring* asks to the *Goals and Metrics* for the high-level plan (initially the set of goals is empty); then the plan is transformed into a set of goals and is sent to the *Decision Support*, which generates a low-level plan based on those goals. The resulting plan is sent back to the *Monitoring*. This module sends the plan to the *Executor* action by action. When each action is executed, the game-state is updated and processed.

```
0.000: (train-unit scv command_center tl_one) [7.0]
7.001: (build-building barracks tl_one) [22.0]
29.002: (build-building supply_depot tl_one) [8.0]
```

Fig. 3. Example of a high-level plan, whose actions will be used as the goal set for the low level.

different levels of abstraction. This version integrates planning, execution, monitoring and goal generation. Figure 2 shows the structure of the agent which is composed of four sub-modules.

- **Monitoring:** it is the central module of the planning agent. It synchronizes the communications among the other modules and monitors the action’s execution i.e. dispatches the next action to *Execution* Module, requests for a new plan to the *Decision Support* and checks for differences between the expected state and the observed state of the environment sent by *Monitoring*. If an observed state is not valid, this module has to start another planning episode to generate a new plan according to the observed state.
- **Executor:** this module runs the actions into the environment by means of the *Brood War Application Programming Interface (BWAPI)*<sup>6</sup>. BWAPI provides a Java Native Interface to the Brood War API that uses the shared memory bridge to give our code access to the game state. Information that can be easily extracted through the API such as units’ state, resources location; or some orders can be issued through training or moving commands. On every frame, JNI-BWAPI sends a game state update to the Java AI agent and waits for a response, which will contain

#### A. Planning, Monitoring and Execution Architecture

We have developed a Planning and Execution agent based on PELEA. We contribute with an extended version of the *Goals and metrics* module

<sup>6</sup><https://code.google.com/p/jnibwapi/>

a set of commands to execute. Besides, this module is responsible for initiating the goal-reasoning, planing and execution loop by sending to the *Monitoring* a particular problem and domain definition to be solved. Both the problem and the domain are described in PDDL.

- **Decision Support:** this module generates a plan of actions by the invocation of a classical planner (Metric FF [9]). When the *Monitoring* informs about a discrepancy between the observed state and the expected planning state, the *Decision Support* invokes the classical planner to generate a new plan.
- **Goals & Metrics:** this module searches and suggests different reachable goals according to the available information about the environment by using a temporal planner (OPTIC [2]). Additionally, this module keeps a registry of the different goals that have been solved in order to generate new goals when all of them have been reached.

#### B. Modeling StarCraft with PDDL

StarCraft uses a lot of complex (numerical and logical) information about the players and the environment to describe the current state of the game. We have described the environment using two abstraction levels that are modelled in PDDL. Our representation of the game state is modeled by using a sequence of binary and numerical values which represent the number of units, buildings and resources available for the players (our player and the opponents) located in the different areas of the map. The specific location of the units or their life points is not relevant for the planning process. Thus, they are omitted.

The game state is described using a sequence of variables (numerical and binary) which represent the units of each player. The map environment is divided into areas of same size. Commonly each area has a set of resources which can

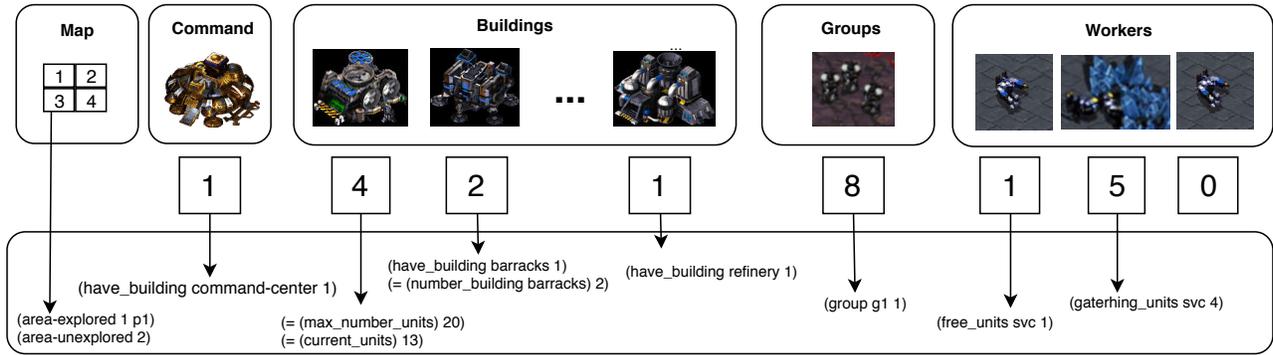


Fig. 4. Transformation of the partial state of the world from StarCraft to PDDL. The numerical sequence of values represents the current state of the game. Positions on the sequence correspond to one of the categories on the top of the Figure. Numbers are mapped into PDDL predicates as in the bottom part of the Figure.

be exploited. The units and buildings are associated to an area in order to have an approximate location of the different units. Figure 4 shows an example of a partial representation of the numeric state, which is later transformed into a PDDL state. In this case, the units of the player are only located in one area and there is not information available about the enemies yet. Each numerical variable is transformed in a set of logical predicates or numerical functions which are included into the game state depending of the abstraction level. The macromanagement level uses some logical predicates, the numerical functions and a group of special functions which can be tuned in order to change the goal generation process: (i) (*goals-score*) which computes the game score of the plan; (ii) (*total-time*) which computes an approximation of the total time to reach the goals; and (iii) (*max-number-goals*) which defines the maximum number of goals that can be generated. The micromanagement level uses only the logical predicates in order to simplify the plan generation. Figure 4 shows an example of the partial representation of the game state, where there is a *Barracks* building which is built in the first area of the map. Thus, the location of each building is going to be represented using two predicates: (i) (*have\_building\_barracks 1*) which means that there is at least one barracks in the area 1 of the map; and (ii) (*number\_building\_barracks 1*) which means which number of barracks are in the area 1. Besides, there are some other predicates that indicates if the agent can be built (*can\_build ?building*) or if the technological level of the agent allows to build that specific building (*tech\_level\_building ?building ?level*).

As a result, we have come up with 10 directed actions and 4 derived actions for the micromanagement level. These actions are used by the classical planner to later perform most of the available game behaviors using the goals generated by the macromanagement level. The directed actions (*move a unit, move a units' group, gather, build, train, research, attack, quarter and explore*) produce changes into the environment and the derived actions (*find-unit, find-building-location, find-*

*explore-location and find-attack-location*) collect information to later execute a directed action.

## V. EXPERIMENTAL RESULTS

This section presents preliminary results when using the Planning and Execution architecture described in Section IV to play on different scenarios from StarCraft. The Brood War Application Programming Interface (BWAPI) was used to connect the executor to the StarCraft game in order to send and receive real-time information from the game. The experiments were conducted on an Intel Core i7-6700T 2.80 GHZ (32 bits) with 3.50 GB running on Windows 7 for the StarCraft simulator and on an Intel Core i7-6700T 2.80 GHZ (64 bits) with 2 GB running on Ubuntu Linux. The maximum planning time for the low-level planner to solve a problem has been set up to 20 seconds and the horizon (*max-number-goals*) for the high-level planner has been set up to 5 and 3 goals. The high-level planner is OPTIC [2] while the low-level planner is METRIC FF [9]. Each scenario has been played 5 times until the game is finished. Initially we tried to compare our approach with some other approaches, but either they had been developed for other platforms or they needed some kind of previous human-directed learning to work properly.

Table I shows the results of playing on StarCraft with our Multilevel Planning approach. We chose three different scenarios (Astral Balance, Baby Steps, Ice Mountain) where three different strategies (greedy, global, parallel) have been deployed. We have used the Terran race. In general, the Multilevel Planning approach can suggest different set of goals and use them to generate short plans to execute actions in the environment. There are two important aspects to analyze in the results: (i) the planning time; and (ii) the number of planning steps. Besides, we have defined three goal-selection policies in order to analyze the influence of the different goals in the planning and execution process: (a) Greedy goal selection, which generate a plan for each goal; (b) Global goal selection, which generate a plan for all goals; and (c) Parallel goal selection, which extracts a subset of goals that can be reached in parallel. Two goals are considered parallel if the

TABLE I

COMPARING THREE GOAL-SELECTION STRATEGIES OVER THREE DIFFERENT MAPS FROM STARCRAFT. THE PERFORMANCE OF THE DIFFERENT STRATEGIES HAVE BEEN MEASURED OVER SIX METRICS. GOALS CORRESPONDS TO THE NUMBER OF GOALS GENERATED DURING THE MATCH. PLANNING STEPS CORRESPONDS TO THE NUMBER OF PLANNING EPISODES. UNITS CORRESPONDS TO THE NUMBER OF UNITS TRAINED. BUILDINGS CORRESPONDS TO THE NUMBER OF BUILDINGS BUILT. PLANNING TIME CORRESPONDS TO THE AVERAGE TIME OF THE PLANNING EPISODES. TIME CORRESPONDS TO THE TOTAL MATCH TIME.

Map	Strategy	Goals	Planning steps	Units	Buildings	Planning time	Time
Astral Balance	Greedy	18	17	8	4	0.3	5:45
Astral Balance	Global	27	6	18	7	3.55	4:36
Astral Balance	Parallel	25	7	17	6	2.94	5:25
Baby Steps	Greedy	16	15	7	4	0.1	4:38
Baby Steps	Global	31	8	20	6	3.12	5:40
Baby Steps	Parallel	29	7	16	7	1.12	5:15
Ice Mountain	Greedy	15	13	9	3	0.4	3:18
Ice Mountain	Global	28	6	15	8	3.55	4:07
Ice Mountain	Parallel	26	9	17	7	2.34	3:56

game actions from which they are derived can be executed in parallel.

On the one hand, the use of methods that generate a larger goal set (global selection and parallel selection) decreases the number of planning steps but increases the planning time on each iteration. The complexity of the problem to solve is increased by the number of goals. On the other hand, the use of a greedy method that generates a small goal set decreases the planning time but increases the number of planning steps making the agent work slower and decreasing the number of actions per iteration that are executed in the environment.

## VI. RELATED WORK

The approach described in this paper is focused on applying Automated Planing (AP) as a reasoning model for a StarCraft autonomous player. There are previous approaches that have used either some other AI techniques for reasoning or AP. SOAR [12] is a cognitive architecture that implements state abstractions, planning and multi-tasking based on Finite State Machines (FMS). This architecture was developed using two layers. First layer is a middleware layer that serves as the perception system and gaming interface. Second layer is composed by a set of FSMs that executes parallel actions into the game according to the information obtained from the first layer.

Darmok [16] is an architecture that implements on-line case-based planning by learning from demonstration on WARGUS (an open source clone of WarCraft II). This architecture employs a planning, execution and monitoring loop, similar to the one used in our approach. The execution cycle analyzes if the last action is finished, updates the current state and picks up the next action. However, Darmok must be first trained by playing a collection of games to generate the case library. In [22], authors present a bot that uses a reactive planning implementation of the Goal-Driven Autonomy (GDA) [15]. UAlbertBot [4] uses a heuristic search algorithm to find concurrent plans of actions which are constrained by unit dependencies and resource availability. Theses plans are focused on creating a certain number of units and structures in the shortest possible time span.

The majority of these approaches use control systems for videogames agents, but only one of them plays on Startcraft. Our approach mainly differs from those previous works in the generation and achievement of goals, which is the main focus of this paper. We do not use any training phase to learn.

## VII. DISCUSSION AND FUTURE WORK

In this paper, we propose a Multilevel Planning approach to perform goal-reasoning and planning on RTSVGs using two different levels of planning. This approach has been deployed using the general-purpose software architecture (PELEA) in order to implement an autonomous player for the video-game StarCraft: Brood War. The preliminary results presented in this paper allow us to draw some very interesting conclusions: (i) it is possible to use AP for goal reasoning according to the information about the environment; (ii) divide the complexity of the environment on different levels decreases the complexity of the planning task and the definition of the domain; and (iii) using a temporal planner to generate a sequence of actions, which is going to be transformed into goals, allows to decrease the information used for planning in the second level. Our contribution presents some advantages: it can be easily improved by adding new actions/goals/information on the domain and being easily adapted to different RSTVGs, as the only domain-dependent parts are the Executor module and the planning domains.

While our initial results are encouraging, there is room to improve the approach presented in this paper. On one hand, the different domains used for planning and goal-reasoning can be refined in order to include more actions to generate new goals or more complex plans of actions. Besides, it is possible to define different domains for the other races of the video-game. On the other hand, we can explore other techniques based in Machine Learning to replace both the goal-reasoning or the planning process: (i) learning goal trees to suggest goals; and (ii) using case-based planning to learn previous plan and avoid some planning and replanning episodes. We could also study HTN planning to analyze its flexibility when working on a dynamic environment; it could complement or replace one of the planners.



## ACKNOWLEDGMENTS

This paper has been partially supported by the European Union's Horizon 2020 Research and Innovation program under Grant Agreement No. 730086 (ERGO) and the Spanish MICINN project TIN2017-88476-C2-2-R.

## REFERENCES

- [1] Mitchell Ai-Chang, John L. Bresina, Leonard Charest, Adam Chase, Jennifer Cheng jung Hsu, Ari K. Jónsson, Bob Kanefsky, Paul H. Morris, Kanna Rajan, Jeffrey Yglesias, Brian G. Chafin, William C. Dias, and Pierre F. Maldague. Mappgen: Mixed-initiative planning and scheduling for the mars exploration rover mission. *IEEE Intelligent Systems*, 19(1):8–12, 2004.
- [2] J. Benton, Amanda Coles, and Andrew Coles. Temporal planning with preferences and time-dependent continuous costs. In *ICAPS*, 2012.
- [3] Sara Bernardini, Maria Fox, and Derek Long. Planning the behaviour of low-cost quadcopters for surveillance missions. In *Proceedings of the Twenty-Fourth International Conference on Automated Planning and Scheduling (ICAPS)*, Portsmouth, New Hampshire, USA, 2014.
- [4] David Churchill and Michael Buro. Build order optimization in starcraft. In *Proceedings of the Seventh AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment (AIIDE 2011)*, pages 10–14, 2011.
- [5] Marc de la Asunción, Luis A. Castillo, Juan Fernández-Olivares, Óscar García-Pérez, Antonio González, and Francisco Palao. SIADEx: an interactive knowledge-based planner for decision support in forest fire fighting. *Artificial Intelligence Communications*, 18(4):257–268, 2005.
- [6] Stefan Edelkamp and Jörg Hoffmann. Pddl 2.2 : The language for the classical part of ipc-4. In *Proceedings of the fourth International Planning Competition. International Conference on Automated Planning and Scheduling*, Whistler, British Columbia, Canada, 2004.
- [7] Maria Fox and Derek Long. Pddl2.1: An extension to pddl for expressing temporal planning domains. *JAIR*, 20, 2003.
- [8] Javier Garca, Jos E. Flez, Ivaro Torralba Arias de Reyna, Daniel Borrajo, Carlos Linares Lpez, Angel Garca Olaya, and Juan Senz. Combining linear programming and automated planning to solve intermodal transportation problems. *European Journal of Operational Research*, 227(1):216–226, 2013.
- [9] Jörg Hoffmann and Bernhard Nebel. The ff planning system: Fast plan generation through heuristic search. *Journal of Artificial Intelligence Research*, 14:253–302, 2001.
- [10] Benjamin Johnson and Mark Roberts. Goal reasoning with informative expectations. In *Proceedings of the Fourth Annual Conference on Advances in Cognitive Systems (ACS-16)*, 2016.
- [11] Richard E. Korf. Real-time heuristic search. *Artificial Intelligence Journal*, 42(2-3):189–211, 1990.
- [12] John E. Laird, Allen Newell, and Paul S. Rosenbloom. Soar: An architecture for general intelligence. *Artificial Intelligence*, 33(1):1–64, sep 1987.
- [13] Moisés Martínez, Fernando Fernández, and Daniel Borrajo. Planning and execution through variable resolution planning. *Journal of Robotics and Autonomous Systems*, In press.
- [14] Matthew Molineaux, Matthew Klenk, and David W. Aha. Goal-driven autonomy in a navy strategy simulation. In *Proceedings of the Twenty-Fourth AAAI Conference on Artificial Intelligence, AAAI 2010, Atlanta, Georgia, USA, July 11-15, 2010*, 2010.
- [15] Héctor Muñoz Avila, Ulit Jaidee, David W. Aha, and Elizabeth Carter. Goal-driven autonomy with case-based reasoning. In *Proceedings of the 18th International Conference on Case-Based Reasoning Research and Development, ICCBR '10*, pages 228–241, Berlin, Heidelberg, 2010. Springer-Verlag.
- [16] Santiago Ontañón, Kinshuk Mishra, Neha Sugandh, and Ashwin Ram. Case-based planning and execution for real-time strategy games. In *Proceedings of the 7th International Conference on Case-Based Reasoning: Case-Based Reasoning Research and Development, ICCBR '07*, pages 164–178, Berlin, Heidelberg, 2007. Springer-Verlag.
- [17] Alison Paredes and Wheeler Ruml. Goal reasoning as multilevel planning. In *Proceedings of the ICAPS-17 Workshop on Integrated Execution of Planning and Acting (IntEx-17)*, 2017.
- [18] Alberto Pozanco, Susana Fernandez, and Daniel Borrajo. Urban traffic control assisted by ai planning and relational learning. In *Proceedings of the 9th International Workshop on Agents in Traffic and Transportation (IJCAI'16)*, 2016.
- [19] Ezequiel Quintero, Vidal Alcázar, Daniel Borrajo, Juan Fernández-Olivares, Fernando Fernández, Angel García Olaya, César Guzmán, Eva Onaindia, and David Prior. Autonomous mobile robot control and learning with the pelea architecture. In *Proceedings of the AAAI-11 Workshop on Automated Action Planning for Autonomous Mobile Robots (PAMR)*, San Francisco, CA, USA, 2011.
- [20] K. Rajan, C. McGann, F. Py, and H. Thomas. Robust mission planning using deliberative autonomy for autonomous underwater vehicles. In *Proceedings of the Workshop on Robotics in Challenging and Hazardous Environments, ICRA*, Rome, Italy, 2007.
- [21] Mark Roberts, Vikas Shivashanka, Ron Alford, Michael Leece, Shubham Gupta, and David W. Aha. Goal reasoning, planning, and acting with actorsim, the actor simulator. In *Proceedings of the Fourth Annual Conference on Advances in Cognitive Systems (ACS-16)*, 2016.
- [22] Ben Weber, Michael Mateas, and Arnab Jhala. Building human-level ai for real-time strategy game. In *Proceedings of AIIDE Fall Symposium on Advances in Cognitive Systems*, 2011.

# A Graphic User Interface for Images Edge Detection. A Proposal to Combine Ant Colony Systems and Fuzzy Logic

M. Angélica Pinninghoff J.  
*University of Concepción*  
Concepción, Chile  
mpinning@udec.cl

Sebastián Espinoza J.  
*University of Concepción*  
Concepción, Chile  
siespinozaj@gmail.com

Ricardo Contreras A.  
*University of Concepción*  
Concepción, Chile  
rcontrer@udec.cl

**Abstract**—The problem of band detection in DGGE images is a key issue in biology because it allows for a correct identification of microbial populations present in biological samples. These particular images present characteristics like image distortion or the presence of noise, that affect the identification process. Traditional mechanisms for edge detection and commercial softwares only partially solve this problem. This proposal introduces a graphical interface which combines ant colony optimization and fuzzy logic to generate a map of edges for classifying pixels that are part of an edge and pixels that are not. The hybrid system is supported with an alternative matrix of pheromone and introduces an alternative set of fuzzy rules.

**Index Terms**—graphic interface, edge detection, ACO systems, fuzzy logic

## I. INTRODUCTION

In artificial vision and in image processing, edge detection deals with the localization and identification of significant gray level variations in a digital image. Localization refers to the search of points at a particular location in a grid of pixels. Identification refers to the process of deciding whether a particular pixel belongs to an edge.

In image processing, an important number of edge detectors have been proposed, exhibiting differences in terms of mathematic and algorithmic properties [9]. One of the standard edge detection methods is proposed by Canny [7], that offers a very effective pixel identification and analyzes every pixel in the image.

Edge detection is carried out through an evaluation of the differences of pixels brightness intensities. The edge detection process is performed by evaluating differences in brightness intensity among pixels that belong to different regions in the image. A region can be characterized as edge or non-edge. It is usual to pre-process an image in such a way that the image contains only the brightness intensity information. These images are known as gray-scale images, in which every pixel holds a value between [0, 255], representing different gray intensity values, from black to white. Usual preprocessing mechanisms are edge thinning or erosion [3]. The effect of erosion on grayscale images is to erode away the boundaries of regions of foreground pixels (i.e. white pixels typically). Thus

areas of foreground pixels shrink in size, and holes within those areas become larger.

Depending on the chosen method and depending on the characteristics of the image, it is possible to identify a pixel as part of an edge when the pixel is actually part of the background of the image. This problem is known as *false positive detection*. Typical characteristics of an image that lead to false positive detection are noise, blurring or lack of contrast between neighbor regions.

When dealing with brightness intensities of pixels as numerical values, it is possible to apply mathematical operations on pixels, to decide whether a particular pixel belongs to an edge. Canny algorithm, one of the best known algorithms for detecting edges, computes the gradient for a pixel (the difference of intensities among a pixels and their neighbors). The requirement of applying a gaussian filter to preprocess the image, has triggered the search for alternative methods to extend the Canny algorithm.

One of the research directions to complement the Canny algorithm, is the procedure known as *Ant Colony Optimization* (ACO), based on the ants behavior in nature [10]. ACO refers to the cooperative working of ants when foraging for food. Although communication between ants during such search is limited, the colony operates far more successfully as a whole than any individual ant within it [16]. Artificial ants manage to establish shortest routes between the colony and a food source. This capability depends upon the production of pheromones and laying of a pheromone trail by individuals ants during their search for a food source. ACO is a population-based metaheuristic that mimics the foraging behavior of ants to find approximate solutions to difficult optimization problems.

ACO has been applied to the edge detection problem, as in the work of [19]. Authors establish a pheromone matrix that represents the edge information presented at each pixel position of the image, according to the movement of a number of ants which are dispatched to move on the image. The movements of these ants are driven by the local variation of the image's intensity values.

The work of [18] proposes an approach that introduces fuzzy logic to decide, with simple rules, the ant's movements



based on heuristic information, with a dynamically updated influence of the pheromone and heuristic information. Authors claim that results are improved with respect to previous experiences that use ACO. This work is important because it gives birth to a new category of edge detectors, that combines optimization through ACO and fuzzy logic inference [20]. This new category is a hybrid ACO-Fuzzy logic system.

In recent years, different researchers have explored the use of fuzzy logic in image processing. In [1] authors propose the use of fuzzy logic for the automatic analysis of X-ray images of industrial products for defect detection. The architecture is based on fuzzy logic and authors claim it is quite tolerant to imprecise input data, and therefore insensitive to noise. In [2], different implementations of the fuzzy system as an edge detector had been overviewed and compared. According to the author, the methods presented shows a better capability to recast the image to new grey level and provide a better tool to get better results in the field of the image edge detection.

In [15], Nawgaje et al. present a Fuzzy Inference System approach to detect the edges of the microscopic images within colour, which is robust and has stability degrees. They proposed the logic based technique which is a set of three pixels and, using the smallest mask of 2\*2 window image, consists of a set of fuzzy rules which highlight all the edges that are correlated with an image.

In [22], authors present the implementation of a simple, flexible and efficient fuzzy logic based algorithm to detect the edges of a vehicle in an input image by scanning it through the 2\*2 mask. The 2\*2 masks is slid over entire vehicle image, and then pixel values of masks are examined through various rules. Based on these set of rules it is decided that particular pixel is edge or not. Peric, in [17] presents a fuzzy set based approach on edge detection, applied to region labeling, a process by which the digital image is divided into units and each unit is given a label (sky, grass, house, and so on).

In [12], authors propose a fuzzy logic based edge detection algorithm for noisy images. The proposed algorithm is based on a 3x3 window mask and fuzzy rules. The window mask and fuzzy rules are defined in a manner such as to detect edges in both noise free and noisy images. The algorithm was tested on grayscale images of size 512x512 pixels, and authors claim it detected all the edge pixels in noisy free and noisy grayscale images. Authors are currently working to extend the method to clinical examination of noisy Magnetic Resonance Images (MRI).

In [13], authors combine fuzzy logic with random walker method (a supervised segmentation method) to make resulting segmentation better in texture and quality. Fuzzy rules are used to approximate boundaries in images which improve segmentation results, when dealing with medical images. The objective of this work is to use a hybrid ACO-Fuzzy logic approach to solve the problem of edge detection on DGGE (Denaturing Gradient Gel Electrophoresis) images.

This article is structured as follows, the first section is the present introduction, the second section describes the theoretical frame supporting this work, the third section describes

design and implementation issues. Section four presents results obtained and the final section shows the conclusions.

## II. THEORETICAL FRAME

In this section, there is a summarized introduction to fundamental concepts involved in this work. While digital images provide the core subject, the main focus is in DGGE images. Then, there is a short introduction to fuzzy logic concepts, and the metaheuristic based on ants behavior: ACO.

### A. Digital images

A digital image is a discrete representation of a two-dimensional image through the use of an image function  $f(x, y)$ , where  $x$  and  $y$  represent coordinates in a two-dimensional space. This function indicates the intensity or level of gray that a particular point in the image (known as pixel) presents. As  $x$  and  $y$  represent discrete locations, a matrix is the usual mechanism for representing a grayscale image.

Information that can be obtained from the matrix include the image resolution (size of the matrix, or number of pixels that define the image) and the color depth, which is the number of color values that can be assigned to a single pixel in an image. As an example, in binary images every pixel is represented by only one bit, which indicates white color, if the value is 1 and the black color if the value is 0; if we use 8 bits for each pixel, we can obtain 256 values in a gray scale ranging from 0 (representing black) to 255 (representing white). Edge pixels are pixels at which the intensity of an image function changes abruptly, and edges (or edge segments) are sets of connected edge pixels. On the other hand, edge detectors are local image processing methods designed to detect edge pixels.

### B. DGGE images

Denaturing Gradient Gel Electrophoresis (DGGE) [5], [14], is a DNA-based technique which generates a genetic profile or *fingerprint* which can be used to identify the dominant members of a microbial community. DGGE has been used to investigate microbial responses in a wide variety of applications, including bioremediation assessment, wastewater treatment, drinking water treatment, biofilm formation, microbial induced corrosion, among others.

DGGE separates mixtures of amplified 16SrRNA gene segments, which are all the same size, based on nucleotide sequence. Denaturing breaks apart the two strands of the DNA molecule. Gradient Gel is a gel with an increasing concentration of a chemical (denaturant) which breaks apart the DNA molecule. Electrophoresis is the application of an electric current across a gel. In response to the current, double-stranded DNA migrates (moves down) the gel. Denaturing the DNA molecule forms Y and T-shaped structures greatly slowing migration. Finally, this process allows to obtain an image composed of bands and lanes [4].

Lanes are the vertical columns shown in Figure 1 and each one of them represents a DNA sample, except the reference lanes which are the leftmost and the rightmost lanes. Reference

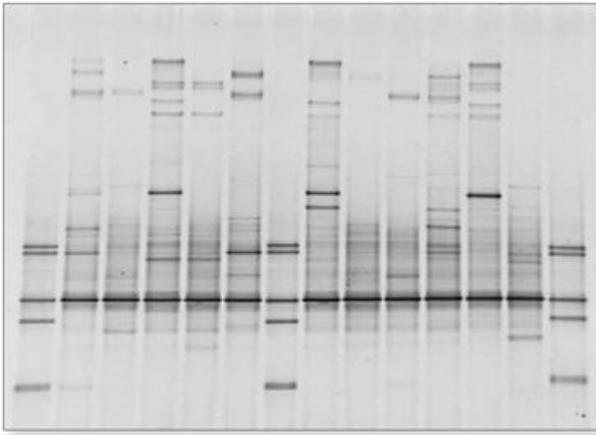


Fig. 1. A typical DGGE image.

lanes are used to indicate the molecular weight, measured in base pairs (*bp*) of the DNA.

### C. Fuzzy logic

In the 60s, Zadeh [23] introduced the concept of partial set membership, to provide a reasoning mechanism that could use fuzzy variables, i.e., variables that define the language subsequently used to discuss a fuzzy concept such as temperature, pressure, age.

According to fuzzy set theory, a fuzzy set  $\mathbf{A}$  on a universe of discourse  $\mathbf{U}$  is characterized by a membership function  $\mu_{\mathbf{A}}(x)$  that takes values in the interval  $[0, 1]$ . Fuzzy sets represent commonsense linguistic values. A given element can be a member of more than one fuzzy set at a time. A fuzzy set  $\mathbf{A}$  in  $\mathbf{U}$  may be represented as a set of ordered pairs, with each pair consisting of a generic element  $x$  and its grade of membership function:

$$\mathbf{A} = \{(x, \mu(x)) \mid x \in \mathbf{U}\} \quad (1)$$

Knowledge is represented in the form of If ... Then rules, and these rules do not work with precisely defined values. Each variable is assigned a fuzzy value such as *high*, *moderate*, *advanced*, etc. These fuzzy values cover a range of measured values.

Our everyday language is full of fuzzy descriptors called linguistic variables. For example, height is often measured in centimeters and tall and short describe regions within this continuous scale. A linguistic variable such as age may have a value such as young, or its antonym, old. However, the great utility of linguistic variables is that they can be modified via linguistic hedges applied to primary terms. These linguistic hedges can be associated with certain functions. Being fuzzy means that there is no clear boundary between the end of one value and the start of another.

Linguistic values are context dependent, in that the range of values they are defined over depends on the variable with which they are associated. Contextual issues for any application are taken into account with a function that is

defined for each linguistic variable value. The purpose of a function is to convert a measured value into a linguistic value (for example, 0 Celsius degree into *freezing*).

Fuzzy rules represent control knowledge and the task of inferencing is to map a series of input variables to a controlling output variable. The mapping from a measured value to a linguistic value is done using a fuzzy membership function. A membership function exists for each linguistic variable value, and the output of that function is a degree of membership that measures the strength of association that a measured value has with a linguistic variable [6].

### D. Ant Colony Optimization

Ant Colony Optimization (ACO) algorithms are metaheuristic techniques usually applied to optimization problems. These approaches are based on the behavior of some foraging ant species, which exhibit the capability of finding the shortest path between the nest and the source of food. Ants do not show an individual behavior, but a collaborative one, under an indirect communication system, by using a specific substance, called pheromone, that ants deposit on the trails they traverse. Ants detect the presence of pheromone and tend to follow trails in which pheromone concentration is higher, which indicates that those trails have been often traversed by other ants.

This ant behavior was studied by Deneubourg [8] and based on these models Dorigo et al. [10] implemented an artificial model to emulate the ants behavior as described by Deneubourg. Results let the researches conclude that the artificial behavior of artificial ants is similar to the natural ant behavior and Dorigo proposed a derivative model for solving optimization problems [11].

Many of the computational problems that belong to the NP-hard class can be seen as optimization problems, and hence it is possible to apply ACO algorithms to obtain solutions that are close to the optimum. Typical examples are the vehicle routing problem, task assignment, and scheduling. Ant-based algorithms are also applied to telecommunications problems and industrial applications [10].

## III. DESIGN AND IMPLEMENTATION

The language chosen for development is Python in a development environment PyQt (based on Qt). The language is a software of free distribution and offers a wide library for scientific applications. At the same time, the language supports the implementation of high user-interaction applications. The software is intended for use by researchers in the Artificial Intelligence and Bioscience domains.

### A. Hybrid Model

The proposed hybrid system in this work is modelled after the one proposed by Tyagi et al. [18], which incorporates ACO and Fuzzy Inference techniques in its behavior. Figure 2 illustrates the general structure of the model. The input image is subjected to grayscale conversion and gaussian filtering as part of the pre-processing stage. Later, this image feeds the Fuzzy Inference component, which characterizes the quality

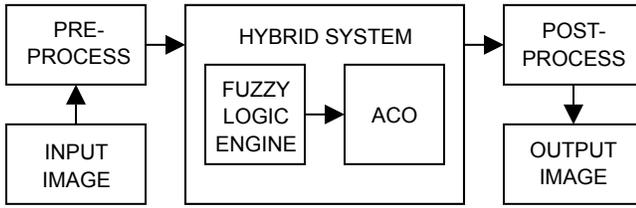


Fig. 2. General structure.

of row, column, or diagonal in its fuzzification step for each pixel in the image; this gives the name to the corresponding fuzzy variables: *Mrow*, *Mcol* and *Idiag*. These variables are further categorized into Low, Medium and High values, with each being modelled as a gaussian function parameterized by center ( $\mu$ ) and width ( $\sigma$ ). Lastly, the fuzzy rules defined in this component determine the output image resulting from the application of a Mamdani-type defuzzification step on each pixel, where the Edginess output variable follows the same categorization scheme as the three input variables described previously.

Once generated, the output image from the preceding stage provides the heuristic data, or Heuristic Matrix, for the ACO component in the model. In this component, a number of artificial ants ( $m$ ) are randomly distributed throughout a uniformly weighted ( $\tau_0$ ) matrix of ones, called Pheromone Matrix, of the same dimensions as the input image. For a number of cycles ( $n$ ), each ant, selected at random, moves a number of contiguous steps ( $s$ ) according to the neighboring pixel (set  $\mathbf{N}$ ) that maximizes the value in Equation 2, where the pheromone ( $\alpha$ ) and heuristic ( $\beta$ ) exponents vary after an ant's movement from pixel  $i$  to  $k$  depending on the difference ( $\Delta$ ) between the minimum and maximum values of its neighbors in the Heuristic Matrix:

$$i_{next} = \underset{k \in \mathbf{N}}{\operatorname{argmax}} \left\{ \tau_k^\alpha \eta_k^\beta \mid k \in \mathbf{N} \right\} \quad (2)$$

This movement produces a pheromone deposition in the ant's destination proportional to the corresponding value ( $\eta$ ) in the Heuristic Matrix. The ants are randomly redistributed on the Pheromone Matrix after the end of each cycle. Finally, the process is subjected to two pheromone evaporation phases: a local one ( $\rho$ ) after the step movement of each ant (Equation 3), and a global one ( $\psi$ ) after the completion of each cycle (Equation 4). The output image of this stage is the resulting Pheromone Matrix.

$$\tau_i \leftarrow (1 - \rho)\tau_i + \rho\eta_i \quad (3)$$

$$\tau_i \leftarrow (1 - \psi)\tau_i + \psi\tau_0 \quad (4)$$

The last stage in the model is post-processing, where each pixel in the produced image is classified into border or non-border by thresholding. In line with other work using the Tyagi et al. Hybrid Model, such as [21], a modification is introduced in the form of an alternative initial Pheromone

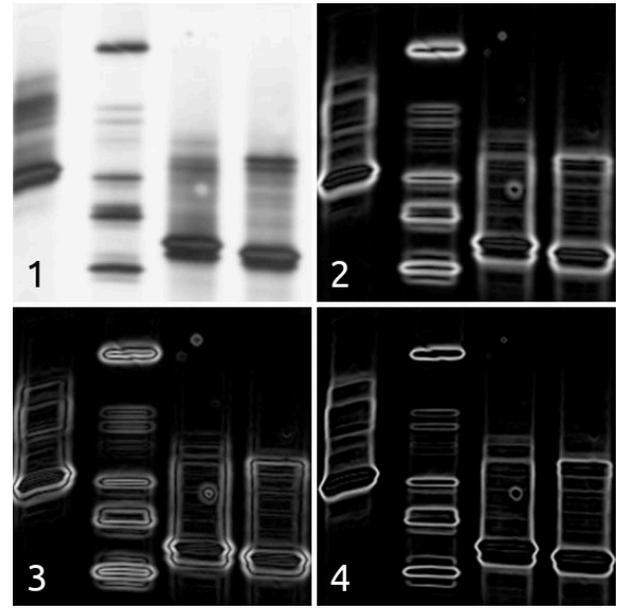


Fig. 3. Effect of subtracting modified laplacian from gradient. 1: original, 2: gradient, 3: modified laplacian, 4: subtraction. Note the formation of creases in the modified laplacian.

Matrix in the ACO sub-system with the intention of reinforcing the potentially relevant border regions in the image. This is done after observing the visual effect in Figure 3, where the subtraction of a modified laplacian (Equation 5) from the gradient of an image (Equation 6) enhances border definition.

$$\hat{\nabla}^2(I) = \frac{d^2}{dx^2}I + 2\frac{d^2}{dx dy}I + \frac{d^2}{dy^2}I \quad (5)$$

$$\hat{\nabla}(I) = \frac{d}{dx}I + \frac{d}{dy}I \quad (6)$$

### B. Interface Usage

Due to the considerable amount of parameters involved in the Tyagi et al. Hybrid System [18], a Graphical User Interface was produced to interactively execute the underlying algorithm, and observe the changes caused by the modification of said parameters. As part of a greater theme of study regarding band detection in DGGE images at UdeC, specific user requirements were stated for inclusion in the developed interface, the most critical of which being the option of segmenting the input image in slices prior to processing, and the possibility of altering the fuzzy rules and variables comprising the Fuzzy Inference sub-system.

A typical workflow of interface use is described as follows: From the Main Window, the user loads the input image into the program. If preferred, the Divide Into Bands Dialog can be summoned to divide the current DGGE image into band slices through user input, which can then be loaded into the software independently. Afterwards, the Adjust Parameters Dialog is accessed to set the number of ants to be used by the ACO sub-system, where this value can be automatically computed from



Fig. 4. Interface dialogs. Top-left: Main Window, top-right: Divide Into Bands, middle-left: Adjust Parameters, middle-right: Manage Fuzzy Rules, bottom-left: Manage Fuzzy Categories, bottom-right: Binarize Image.

the image's dimensions. Additional parameters from the ACO sub-system can be modified through Adjust Parameters Dialog, whereas fuzzy rules and categories from the Fuzzy Inference sub-system can be edited in the Manage Fuzzy Rules Dialog and Manage Fuzzy Categories Dialog, respectively. Optionally, the user may want to save the current model configuration as a file in order to retrieve it at a later time.

It is appropriate at this stage to begin executing the system by pressing the Start button from Main Window. A status bar will indicate the processing state of the program, and its completion will display the Binarize Image Dialog, where the resulting border map under the application of isodata thresholding, will be shown. Finally, the user will be able to alter the suggested thresholding value and save the generated image to a file from this same screen.

Figure 4 showcases the relevant screens of the interface, while Figure 5 presents the potential use cases encountered throughout the software's usage.

#### IV. RESULTS

The system has been tested under different configurations and results are promising.

The system has been tested under different configurations, and its results are promising and similar to those obtained by using other mechanisms. The image shown in Figure 5, represents a test in which the proposed mechanism obtain a 79% of edges with respect to the best approach, proposed in [18]. Here a) is the original lane, b) shows the results obtained

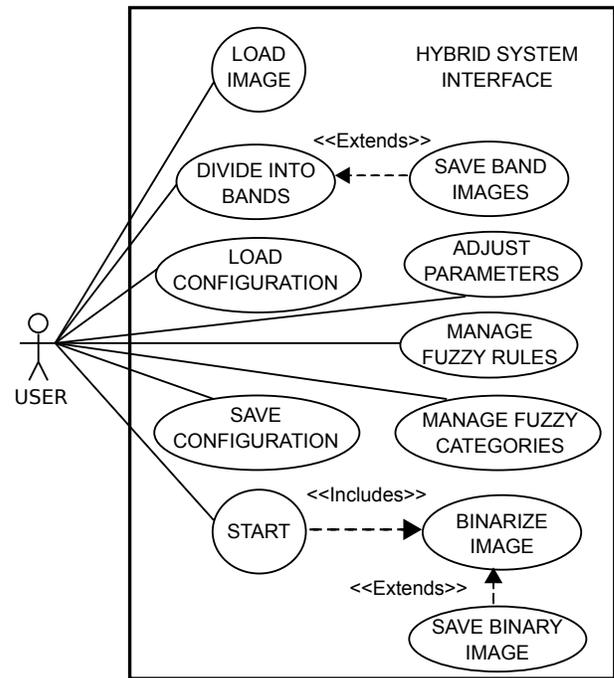


Fig. 5. Use case diagram of the hybrid system interface.

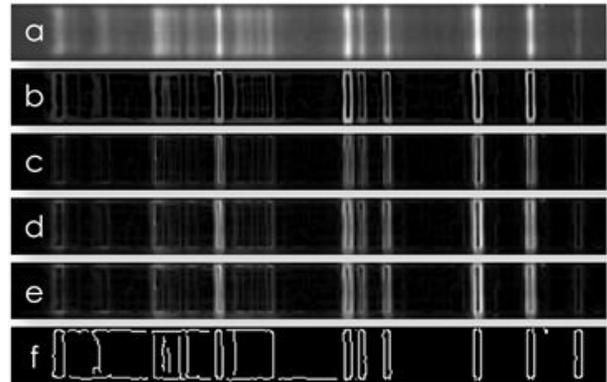


Fig. 6. Results. It takes into account different edge detection mechanisms.

with the hybrid proposal, c) is the result obtained when using Roberts, d) is the result obtained when using Prewitt, e) is the result obtained using Sobel mechanism, and f) is the result obtained with Canny. Taking into account the fact that the interface allows to manage fuzzy rules and other parameters, it is possible to obtain improved results after an adjustment of parameters and rules.

#### V. CONCLUSIONS

The proposed interface represents an interesting alternative to detect edges in DGGE images. The alternative pheromone matrix enhances the model in a way to focus ants' search in the regions where there is a greater probability of containing edges, while providing the added benefit of obtaining leaner borders.



On the other hand, the developed interface is a very flexible tool that permits the exploration of diverse edge detection strategies within the hybrid model, as it is designed to permit the manipulation of its intrinsic parameters, as well as to readily visualize the impact these changes have upon the general behavior of the system.

- [22] Walad, K.P., Shetty, J. *Fuzzy Logic Based Edge Detection Using Trapezoidal and Triangular Member Function*. International Journal of Engineering Research and General Science, Vol. 3, Issue 1, January-February 2015.
- [23] Zadeh, L.A. *Fuzzy Sets*. Information and Control, Vol. 8, No. 3, pp. 338 - 353, 1965.

## REFERENCES

- [1] Amza, C.G., Cicic, D.T. *Industrial Image Processing Using Fuzzy-Logic*. 25th DAAAM International Symposium on Intelligent Manufacturing and Automation, Procedia Engineering 100 (2015), pp. 492 - 498, 2014.
- [2] Anas, E. *Edge detection techniques using fuzzy logic*. International Conference on Signal Processing and Integrated Networks, pp. 169-173, 2016.
- [3] Auer, C., Bachmaier, C., Brandenburg, F., Reislhuber, J. *Optical Graph Recognition*. Journal of Graph Algorithms and Applications. Vol. 17, no. 4, pp. 541 - 565, 2013.
- [4] Borrajo, M.L., Baroque, B., Corchado, E., Bajo, J., Corchado, J.M. *Hybrid neural intelligent system to predict business failure in SMEs*. International Journal of Neural Systems 21(04), 277 - 296, 2011.
- [5] Borresen, A.L., Hovig, E., Brogger, A. *Detection of base mutations in genomic DNA using denaturing gradient gel electrophoresis (DGGE) followed by transfer and hybridization with gene-specific probes*. Mutation Research/Fundamental and Molecular Mechanisms of Mutagenesis 202, 77 - 83, 1988.
- [6] Callan, R. *Artificial Intelligence*. Macmillan Education UK, 2003.
- [7] Canny, J. *A computational approach to edge detection*. In Transactions on Pattern Analysis and Machine Intelligence, Vol. 6, pp. 679 -698, 1986.
- [8] Deneubourg, J.L., Goss, S., Pasteels, J.M., Beckers, R. *Collective decisionmaking through food recruitment*. Insectes sociaux, 1990.
- [9] Ziou, D., Tabbone, S., et al. *Edge detection techniques - An overview*. In Pattern Recognition and Image Analysis C/C of Raspoznvaniye Obrazov I Analiz Izobrazhenii, Nauka/Interperiodica Publishing, Vol. 8, pp: 537-559, 1998.
- [10] Dorigo, M., Stutzle, T. *Ant Colony Optimization*. The MIT Press, 2004.
- [11] Dorigo, M. and Di Caro, G. *The Ant Colony Optimization Meta-Heuristic*. In New Ideas in Optimization, 1999.
- [12] Izhar, ul Haq, I., Shah, K., Khan, M.T., Azam, K., Anwar, S. *Fuzzy Logic Based Edge Detection for Noisy Images*. Technical Journal, University of Engineering and Technology (UET) Taxila, Pakistan, Vol. 20(SI), No. II(S), 2015.
- [13] Kaur, J., Mahajan, M. *Hybrid of Fuzzy Logic and Random Walker Method for Medical Image Segmentation*. IJ Image, Graphics and Signal Processing, Vol. 2, pp. 23 - 29, 2015.
- [14] Muyzer, G.m de Waal, E.C., Uitterlinden, A.G. *Profiling of complex microbial populations by denaturig gradient gel electrophoresis analysis of polynerase chain reaction amplified genes coding for 16SrRNA*. Applied and Environmental Microbiology 59(3), 695 - 700, 1993.
- [15] Nawgaje, D.D, Rajendra, Dr., Kanphade, D. *Implementation of fuzzy logic for detection of suspicious masses in mammogramms using DSP TMS320C6711*. International Journal of Advanced Engineering and Application, 2011.
- [16] Parmee, I. *Evolutionary and Adaptive Computing Engineering Design*. Springer, 2001.
- [17] Peric, N. *Fuzzy Logic and Fuzzy Set Theory Based Edge Detection Algorithm*. Serbian Journal of Electrical Engineering. Vol. 12, No. 1, pp. 109 - 116, 2015.
- [18] Puntambekar, T., Sexena, P., Tanwani, P., Tyagi, V. *A Hybrid Approach to Edge Detection Using Ant Colony Optimization and Fuzzy Logic*. International Journal of Hybrid Information Technology. Vol. 5, No. 1, January 2012.
- [19] Tian, J., Yu, W., Xie, S. *An ant colony optimization algorithm for image edge detection*. Evolutionary Computation 2008, CEC 2008, Hong Kong, China, September 2008.
- [20] Trillas, E., Eciolaza, L. *Fuzzy Logic: An Introductory Course for Engineering Students*. Springer, 2015.
- [21] Villagran, H. [Hybridization of ACO Algorithms in Edge Detection in DGGE Images]. Universidad de Concepcion, 2015. (In Spanish).

# Doble modelo de fuerzas gravitacionales para procesamiento de imagen

Cedric Marco-Detchart

*Estadística, Informática y Matemáticas*  
Universidad Pública de Navarra  
Pamplona, Spain  
cedric.marco@unavarra.com

Javier Fernandez

*Estadística, Informática y Matemáticas*  
Universidad Pública de Navarra  
Pamplona, Spain  
fcojavier.fernandez@unavarra.com

Humberto Bustince

*Estadística, Informática y Matemáticas*  
Universidad Pública de Navarra  
Pamplona, Spain  
bustince@unavarra.com

**Abstract**—En este trabajo se presenta un nuevo método de procesamiento de imagen basado en el movimiento de partículas debido a las fuerzas de atracción gravitacionales. Describimos el modelo de fuerzas gravitacionales como un método iterativo y estudiamos el efecto de sus diferentes parámetros. Probamos sus utilidad sobre dos aplicaciones clásicas de procesamiento de imagen, como son el suavizado y la segmentación. Realizamos la experimentación y el análisis de los resultados sobre imágenes en color.

**Index Terms**—fuerza gravitacional, suavizado, segmentación, representación jerárquica

## I. INTRODUCCIÓN

Las técnicas para abordar problemas en temas de inteligencia artificial se han inspirado considerablemente de la naturaleza. Un ejemplo clásico es el análisis de las conexiones neuronales de nuestro cerebro que ha desembocado en la teoría de las redes neuronales artificiales, cuyo estudio está actualmente en auge, por ejemplo, en problemas de clasificación [1]. Otra fuente de inspiración natural proviene de la teoría de la evolución, que ha contribuido a generar herramientas para la resolución de problemas de optimización y búsqueda de parámetros específicos en determinados problemas. Un buen ejemplo son los algoritmos genéticos, cuyo funcionamiento consiste en tomar una población de posible soluciones y hacerla evolucionar hasta llegar a una solución con el menor error posible [2]. En cuanto a la inspiración proveniente del comportamiento animal, contamos con numerosos ejemplos, como pueden ser las representaciones basadas en el funcionamiento de los enjambres [3] o las colonias de hormigas [4].

Estrechamente relacionado con el mundo natural y su comportamiento, encontramos la teoría física de la Ley de Gravitación Universal (LUG) [5], que ha servido de base para muchos investigadores a la hora de generar modelos basados en las fuerzas gravitacionales. Su objetivo es aplicar un modelo físico del mundo real a un problema matemático. Estos modelos centran su atención principalmente en temas como el clustering o los problemas de optimización.

El clustering gravitacional, presentado por Wright [6], considera los datos a procesar como partículas en un sistema, con una posición inicial y una masa, que se mueven debido a las fuerzas que ejercen entre ellas. El movimiento del sistema cesa cuando solamente queda una partícula que representa el

total de los elementos. En esta misma temática una propuesta similar fue presentada por Gomez *et al.* [7] donde se describe un sistema gravitacional más elaborado. En dicho sistema se incluyen conceptos como la aceleración o la velocidad de las partículas. En cuanto a los problemas de optimización, Rashedi *et al.* presentaron el algoritmo de búsqueda gravitacional [8] que condidera la ley de gravitación y la masa de las partículas para construir un sistema multi-agente para la búsqueda de la mejor solución a un problema dado.

Respecto al procesamiento de imagen, encontramos una técnica interesante aplicada a detección de bordes presentada en [9] que considera los píxeles de una imagen como partículas y utiliza las fuerzas gravitacionales para detectar cambios de intensidad en la imagen.

Nuestro objetivo con este trabajo es aunar las propuestas presentadas en el clustering gravitacional de Wright y el detector de bordes gravitacional, aplicando un modelo de fuerzas gravitacionales para regularización de imagen y segmentación.

La aplicación que se presenta en este trabajo utiliza nuestra propuesta de manera doble. Por un lado, para obtener una imagen suavizada medimos la fuerza que ejercen cada uno de los píxeles de la imagen entre ellos. Esta fuerza representa el movimiento que se realiza en el espacio de color de manera que se vayan obteniendo regiones planas con colores homogéneos. Por otro lado, extraemos superpíxeles [10] a partir de las imágenes suavizadas y los combinamos aplicando nuestra propuesta de fuerzas gravitacionales, consiguiendo una representación jerárquica de la imagen. Dicha representación permite obtener los diferentes niveles de detalle de los objetos presentes en la imagen.

La estructura de este trabajo consta de las siguientes partes. En la Sección II exponemos algunos de los conceptos utilizados en el trabajo. La Sección III introduce el concepto de fuerza gravitacional y su aplicación al procesamiento de señal; concretamente en la Sección III-A se presenta la propuesta para suavizado de imagen y en la Sección III-B la referente a segmentación. Finalmente el estudio experimental se lleva a cabo en la Sección IV, presentando algunos resultados y conclusiones.



## II. PRELIMINARES

En esta sección recordamos algunos de los conceptos básicos relativos a procesamiento de imagen y teoría de fuerzas gravitacionales. En nuestra propuesta representamos una imagen como una función  $f : D \subseteq \mathbb{R}^2 \mapsto L$ , donde  $D$  representa el dominio como el producto cartesiano de dos conjuntos discretos y  $L$  el posible conjunto de valores de cada elemento (píxel) de la imagen. En concreto,  $D = X \times Y = \{1, \dots, w\} \times \{1, \dots, h\}$ , donde  $w$  representa la anchura, es decir, el número de columnas de la imagen, y  $h$  la altura, es decir, el número de filas de la imagen.

La utilización de  $L$  nos permite representar diferentes tipos de imagen. En el caso de imágenes binarias los píxeles pueden tomar valores en  $L = \{0, 1\}$ , mientras que en el caso de imágenes en escala de grises lo hacen en  $L = \{0, \dots, 255\}$ , y para las imágenes en el espacio de color RGB el rango de posibles valores es  $L = \{0, \dots, 255\}^3$ . Existen otros espacios de color como CIELAB, donde el rango de valores no está tan bien definido como en RGB. CIELAB consta de tres componentes ( $L^*ab$ ), que representan la luminosidad ( $L^*$ ), el ángulo entre los colores verde y rojo ( $a$ ) y el ángulo entre el azul y el amarillo ( $b$ ). Representamos una imagen que toma valores en  $L$  como  $\mathbb{I}_L$ .

Este trabajo se ha llevado a cabo utilizando imágenes en el espacio de color RGB para el caso del proceso de regularización y en el espacio CIELAB para la parte de clustering.

La ley de gravitación universal establece que todo objeto es atraído por otro objeto con una fuerza directamente proporcional al producto de sus masas e inversamente proporcional a la distancia que los separa. Podemos ver una representación esquemática ilustrando la fuerza entre dos partículas en la Figura 1. La fuerza existente entre dos partículas es un vector calculado mediante la Ecuación 1, donde  $i, j$  representan cada una de las partículas,  $m_i$  y  $m_j$  son sus masas y el vector  $\vec{r}$  es la distancia entre ellas. Habitualmente dicha distancia es la Euclídea.

$$\vec{f}_{ij} = G \cdot \frac{m_i \cdot m_j}{\|\vec{r}\|^2} \cdot \frac{\vec{r}}{\|\vec{r}\|} \quad (1)$$

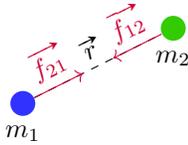


Fig. 1: Fuerza de atracción entre dos partículas

La fuerza total ejercida sobre una partícula es la suma de todas las fuerzas realizadas por el resto de partículas a su alrededor, tal como se indica en la siguiente expresión:

$$\|\vec{F}_i\| = \sum_{\substack{j \in N \\ i \neq j}} G \cdot \frac{m_i \cdot m_j}{\|\vec{r}\|^2} \cdot \frac{\vec{r}}{\|\vec{r}\|} \quad (2)$$

donde  $N$  representa todas las partículas del sistema.

## III. PROCESAMIENTO GRAVITACIONAL DE IMÁGENES

Desde la presentación del modelo gravitacional por parte de Wright para clustering de datos han surgido numerosas investigaciones inspiradas por este modelo. Algunas de las técnicas se han aplicado a procesamiento de imagen, en concreto al análisis de texturas [11] y a la detección de bordes [9]. Nuestra propuesta recoge la idea del modelo de Wright y aplica sus conceptos a la regularización de imágenes y a su segmentación de manera jerárquica.

### A. Regularización de imagen

La regularización de imágenes sustituyendo la información de sus píxeles por medio de una función dependiente de la información de los píxeles vecinos puede llevar a una pérdida de definición de la imagen. El efecto que se obtiene es una imagen borrosa, como puede ocurrir al aplicar la media o el filtro Gaussiano. Este comportamiento puede ser válido para eliminar el ruido existente en una imagen o reducir el efecto del muestreo, pero no es apto, por ejemplo, para detección de bordes o tratamiento de imágenes por satélite. En la literatura existente encontramos técnicas que consideran el caso particular de los bordes, donde la regularización de la imagen conserva su definición. Para poder llevar a cabo una regularización de la imagen preservando sus bordes, la influencia de la regularización se debe adaptar y cambiar según las condiciones de la información local.

Existe una gran variedad de técnicas que eliminan la información innecesaria a la par que conservan aquella relativa a los bordes. Entre estas técnicas contamos con el filtrado bilateral [12], donde los valores de cada píxel son el resultado de una media ponderada dependiente de la información espacial y tonal aplicados sobre una ventana de tamaño fijo. Otra de las técnicas en este ámbito es el conocido Mean Shift [13], donde la información considerada va más allá de una ventana fija, variando su tamaño según la información local.

Adoptando el proceso de tomar la información del vecindario de un píxel, en este trabajo, imitamos el movimiento generado por la influencia de fuerzas gravitacionales existentes entre los píxeles para modificar su valor. El modelo gravitacional establece que cada partícula ejerce una influencia sobre todas las demás; con una pequeña cantidad de partículas esta norma es admisible, pero en el caso de una imagen donde el número de píxeles es muy grande, calcular cada una de las fuerzas ejercidas entre cada par de píxeles se convierte en una tarea computacionalmente prohibitiva. Debido a que la fuerza gravitacional depende de la distancia, aquellas partículas que se encuentran lejos de la posición considerada tendrán menos influencia. Aprovechando este hecho, consideramos que todas las partículas que se encuentren más allá de una determinada distancia no ejercen ninguna influencia, es decir, su fuerza es cero. La región de influencia considerada alrededor de cada píxel se establece mediante una máscara circular. Cada posición de la máscara se utiliza para saber que píxeles están ejerciendo influencia sobre la posición central.

Uno de los elementos clave del cálculo de la fuerza total (Eq. 2) es la medida de distancia considerada entre dos partícu-

las. En nuestro modelo representamos las partículas mediante un vector  $n$ -dimensional. Por ejemplo, para una imagen RGB, el píxel de la posición  $p$  sería  $\mathbb{I}(p) = [x, y, r, g, b]$ . En el caso de imágenes en el espacio de color RGB combinamos la posición espacial del píxel con cada una de las componentes de color. Mientras que para los descriptores espaciales,  $[x, y]$ , no se conoce a priori su rango de valores ya que depende del tamaño de la imagen, para la información relativa al color,  $[r, g, b]$ , los posibles valores se encuentran en  $L$ . El principal problema existente con esta representación es la disimilitud entre los rangos de posibles valores de cada uno de los componentes.

Si consideramos el descriptor completo, es decir, los cinco componentes que representan la posición y la información relativa al color, puede darse una inconsistencia en el cálculo de la distancia. Además, si normalizamos los valores de la intensidad de color para llevarlos al rango  $[0, 1]$ , la diferencia de rango entre la información espacial y de color es todavía mayor. Hacer uso de la distancia Euclídea directamente con el vector 5-dimensional resultaría en una distancia influenciada principalmente por la información espacial.

Partiendo de la base de la distancia Euclídea, separamos su cálculo en una parte espacial y otra tonal. Así podemos añadir un peso al cálculo de la distancia que nos permite controlar la influencia de cada una de las partes. Con esta modificación el cálculo de la distancia se realiza mediante la siguiente expresión:

$$r_s = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

$$r_c = \sqrt{(r_1 - r_2)^2 + (g_1 - g_2)^2 + (b_1 - b_2)^2}$$

$$r = r_s + r_c \cdot \omega_c$$

El factor de influencia,  $\omega_c$ , nos permite controlar la importancia asignada o bien a la distancia espacial o a la distancia en color. Tal como se observa en la experimentación con este parámetro somos capaces además de controlar el nivel de borrosidad aplicado al final del proceso. Para poder obtener resultados admisibles un cuanto a suavizado sin perder definición de bordes, los experimentos realizados sugieren que el valor de  $\omega_c$  debe tomarse en el rango  $[1, 100]$ .

En un primer paso, dada una máscara  $m$  de radio  $\tau = 7$  calculamos una imagen de fuerzas, representada como  $\mathbb{I}_F$ . Cada una de las posiciones  $p$  de dicha imagen en cada uno de los canales (RGB) indica la fuerza total (Eq. 2) que actúa sobre esa posición. Esto significa que en cada posición tenemos el valor de intensidad que debe variar el píxel de esa posición. La fuerza que se ejerce sobre cada una de las partículas se calcula considerando que su masa es igual a uno, ya que cada partícula representa un píxel.

El principal problema que surge con el cálculo de la fuerza es que el valor final de la información de color se mantenga en el rango  $L$ . Si la fuerza obtenida es demasiado fuerte, el resultado de aplicarla sobre la intensidad de color actual del píxel correspondiente puede resultar en un valor fuera de rango y perder sentido. La solución aportada es hacer uso de la constante gravitacional  $G$  presente en la Ecuación 1. Esta constante nos permite adaptar la fuerza final y hacer que tenga

mayor o menor influencia. En este sentido, tomar valores de  $G$  altos hace que las partículas del sistema gravitacional varíen con mayor intensidad de manera que se obtiene una imagen suavizada en un menor lapso de tiempo. Por el contrario, con valores bajos de  $G$  la variación será menor y el resultado final del suavizado tardará más tiempo.

Entre el número de iteraciones máximo y los dos parámetros,  $\omega_c$  y  $G$ , de nuestro modelo tenemos un amplio rango de posibilidades para poder controlar el nivel de suavizado de las imágenes. En el caso de  $G$  elegimos valores comprendidos entre  $(0, 0.1]$ . Además, debido a que estamos imitando un sistema gravitacional, la variación de intensidad debe ser baja para representar el movimiento constante de las partículas. Si  $G \approx 0$ , la fuerza ejercida sobre cada píxel será casi imperceptible, mientras que si tomamos  $G = 0.1$  la intensidad de los píxeles variarán en un orden máximo de  $10^{-3}$ . Estos órdenes son consecuentes con el factor de color aplicado en el cálculo de la distancia. Una vez calculada la fuerza total sobre cada posición se aplica sobre la imagen de manera iterativa:

$$\mathbb{I}_L(p)_{t+1} = \mathbb{I}_L(p)_t + \mathbb{I}_F(p)_t \quad (3)$$

Para el cálculo de los nuevos valores en cada una de las posiciones de la imagen suavizada solamente consideramos la fuerza ejercida sobre la información relativa a la intensidad de color. De este modo mantenemos la estructura matricial de los píxeles y obtenemos una imagen regularizada en el espacio de color.

### B. Segmentación de imagen

La segmentación de imagen es una de las tareas más importantes en visión por computador. Es una de las tareas más complejas que ha sido y sigue siendo estudiada en profundidad [14]. El principal reto de la segmentación de imagen radica en el hecho de que no existe una única solución. Incluso para el caso de los seres humanos, que son capaces de identificar rápidamente objetos en una imagen, la definición de un objeto o de sus partes puede ser múltiple y no presentar una forma clara. Esta problemática puede verse reflejada en las imágenes proporcionadas por los expertos del conjunto de datos de Berkeley Segmentation Dataset (BSDS) [15], donde cada imagen cuenta con hasta cinco posibles soluciones propuestas por seres humanos. En este sentido, aunque las personas son capaces de percibir muchos patrones y asociarlos con objetos, el hecho de definir una partición de una imagen es una tarea compleja.

Además, no todos los objetos de una imagen tienen la misma importancia, se deben tener en cuenta los diferentes niveles de detalle que pueden existir. Los estudios llevados a cabo sobre la percepción humana establecen que las personas son capaces de definir objetos a diferentes niveles de detalle [16], asociando partes de la imagen a través de propiedades que las caracterizan, como por ejemplo, el color o la forma. Para poder gestionar los diferentes niveles de detalle en imágenes, e imitar la percepción humana, los investigadores



se han centrado en la segmentación jerárquica o la fusión de regiones [17]. Los diferentes niveles de una jerarquía se pueden representar mediante lo que se conoce como un mapa de contornos ultra métrico (UCM) [18],

En nuestra propuesta generamos una partición inicial de la imagen formada por regiones primarias conocidas como superpíxeles. Esta imagen es una sobre-segmentación, lo que significa que hay más particiones que objetos reales en la imagen. Generamos los superpíxeles iniciales mediante la aplicación de la transformada watershed [19] sobre una imagen de magnitud de gradiente de una imagen pre-procesada con el algoritmo de suavizado gravitacional. Para limitar el número de superpíxeles extraídos eliminamos todos aquellos valores de la magnitud del gradiente que se encuentran por debajo de la mediana de todos los mínimos regionales [20]. A partir de los superpíxeles iniciales, los vamos fusionando de manera progresiva hasta que únicamente quede uno solo, que representa el contenido de toda la imagen.

Contrariamente al proceso de suavizado, cuando trabajamos con superpíxeles, la masa de cada partícula depende del tamaño del superpíxel, es decir, del número de píxeles que contiene esa región. Para ajustar los valores de las masas a un espacio más reducido les aplicamos una escala logarítmica. Además, la distancia que utilizamos en esta fase de agrupación de regiones varía con respecto a la sección anterior; en este caso no medimos la distancia entre elementos individuales. El cálculo de la distancia del color permanece intacta, medida en este caso entre el color medio de los superpíxeles, mientras que la distancia espacial se realiza utilizando la siguiente expresión:

$$D_s = 1 + d\{A, B\}$$

donde  $d$  es la mínima distancia Euclídea entre los superpíxeles  $A$  y  $B$ ; obtenemos así la distancia entre la pareja de píxeles más cercanos de las dos regiones. Posteriormente combinamos la distancia entre la información del color y la espacial mediante el factor  $\omega_c$ .

#### IV. ESTUDIO EXPERIMENTAL

El algoritmo gravitacional propuesto en este trabajo en la Sección III se ilustra a través del siguiente experimento, aplicado a suavizado y segmentación de imagen.

Por un lado, examinamos la influencia que el número de iteraciones y el parámetro  $\omega_c$  tienen sobre el suavizado gravitacional. Por otro lado, dadas las diferentes imágenes suavizadas evaluamos como afecta el suavizado en el proceso de segmentación y fusión jerárquica. Evaluamos el algoritmo propuesto con un máximo de 300 iteraciones y tomando una serie de instantáneas cada cierto instante de tiempo  $t = \{10, 40, 80, 100, 140, 220, 260, 300\}$ . En el caso del proceso de segmentación utilizamos el operador de Canny [21] con  $\sigma = 2$  para obtener la magnitud del gradiente de la imagen. Con el resultado obtenido construimos un mapa de superpíxeles mediante la transformada watershed.

Para la realización de los experimentos hemos utilizado 200 imágenes del conjunto de datos de test del Berke-

ley Segmentation Dataset (BSDS500) [15]. Para cada UCM obtenida en cada instante de tiempo  $t$  aplicamos un umbral  $th = \{0.17, 0.33, 0.50, 0.67, 0.83\}$  para obtener una imagen de bordes binaria. Dicha imagen de bordes se evalúa como un proceso de correspondencia con las imágenes de los expertos proporcionadas por el conjunto de datos. Este proceso de correspondencia se lleva a cabo mediante la técnica presentada por Estrada y Jepson [22] calculando las siguientes medidas de precisión ( $Prec$ ) y exhaustividad ( $Rec$ ):

$$Prec = \frac{TP}{TP + FP}, \quad Rec = \frac{TP}{TP + FN},$$

$$F_\alpha = \frac{Prec \cdot Rec}{\alpha \cdot Prec + (1 - \alpha) \cdot Rec}.$$

Para el cálculo de  $F_\alpha$  utilizamos  $\alpha = 0.5$  tal como se indica en [23].

Como se muestra en la Figura 2 el paso del tiempo afecta el proceso de suavizado. A medida que las iteraciones van creciendo, van apareciendo zonas planas en aquellas regiones donde los colores son similares. Se preservan los bordes de los objetos hasta que las regiones son completamente homogéneas. Cuando una región acaba siendo totalmente plana, los diferentes colores cercanos comienzan a mezclarse resultando en un suavizado de los bordes y por consiguiente en una pérdida de definición de los mismos.

Podemos observar en la parte superior que con un valor bajo de  $\omega_c = 40$  el efecto borroso es más pronunciado. Si nos centramos en los dos peces cerca de los corales, podemos ver como la parte blanca de la aleta se va difuminando progresivamente hasta que acaba desapareciendo fusionándose con la parte más oscura del mar. En la parte inferior de la figura, los dos peces permanecen bien definidos a lo largo de todo el proceso iterativo, conservando sus bordes.

La influencia del proceso de suavizado se puede observar claramente en la Figura 3. La segmentación inicial contiene una menor cantidad de superpíxeles conforme el proceso de suavizado homogeneiza los colores de la imagen. Esta reducción en el número de superpíxeles inicial tiene un efecto directo en la construcción de la jerarquía ya que las pequeñas regiones aisladas desaparecen, quedando absorbidas por regiones contiguas al inicio del proceso.

En cuanto a la evaluación cuantitativa, en la Figura 4, observamos como el efecto de suavizado generado por el valor bajo de  $\omega_c = 40$  (Figure 4a), afecta significativamente al proceso de segmentación. En las iteraciones iniciales, hasta  $t = 80$ , el valor de  $F_{0.5}$  se mantiene estable en todos los umbrales aplicados. Por un lado, observamos como en las iteraciones iniciales los mejores valores se obtienen con el segundo umbral. Esto indica que con un menor número de iteraciones necesitamos un umbral mayor para eliminar las regiones de menor tamaño que no son aptas para definir los contornos de la imagen. Por otro lado, en las iteraciones finales obtenemos el valor  $F_{0.5}$  más alto con el menor umbral. Esto significa que el efecto de suavizado ha provocado borrosidad y los diferentes colores se han fusionado por lo que la distancia entre superpíxeles es menor.



Fig. 2: Resultados obtenidos con la aplicación de nuestro algoritmo de suavizado gravitacional sobre la imagen 101027 del BSDS500 en diferentes instantes de tiempo. Utilizamos el factor de color  $\omega_c \in \{40, 70\}$ , la constante  $G = 0.05$  y ejecutamos el método con 300 iteraciones.



Fig. 3: Imágenes de superpíxeles obtenidas en diferentes tiempos  $t$  del suavizado gravitacional sobre la imagen 118035 del BSDS500. Utilizamos el factor de color  $\omega_c = 70$  y  $G = 0.05$ .

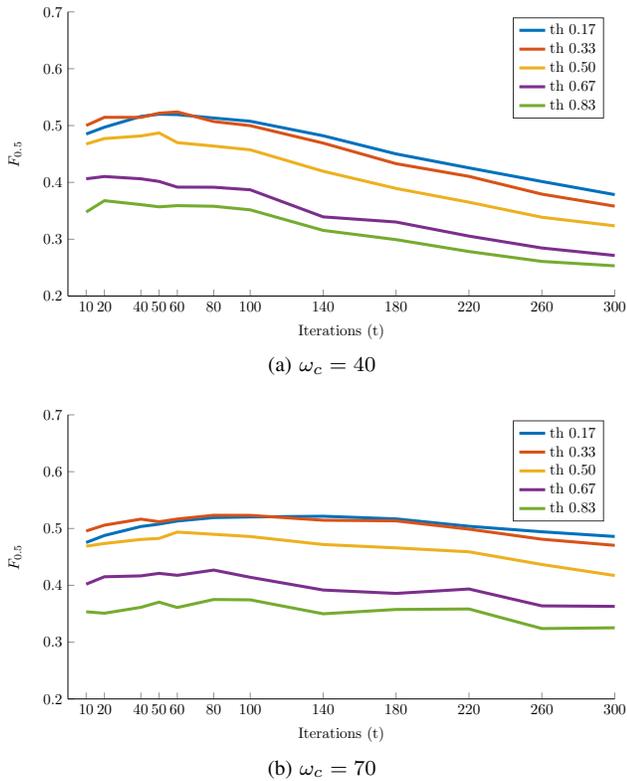


Fig. 4: Medida de  $F_{\alpha}$  sobre 300 iteraciones con  $G = 0.05$  aplicando diferentes umbrales sobre las imágenes UCM obtenidas en el proceso de segmentación jerárquica.

Al observar el proceso, pero con un valor de  $\omega_c = 70$  en la Figura 4b vemos como los valores de  $F_{0.5}$  se mantienen más estables a lo largo del proceso. Este comportamiento confirma el hecho de que el efecto de borrosidad es menos pronunciado y se conserva una buena definición de los bordes. El mejor resultado para este valor de  $\omega_c$  se obtiene en el punto intermedio del proceso, en la iteración  $t = 140$ . A partir de este punto los resultados comienzan a decaer, pero la disminución es menos pronunciada que en el caso de  $\omega_c = 40$ .

## V. CONCLUSIONES

Hemos presentado un nuevo método para obtener imágenes suavizadas, mediante un modelo físico basado en las fuerzas gravitacionales de atracción entre partículas. Hemos introducido los conceptos matemáticos necesarios para el uso del modelo expuesto en problemas relacionados con información proveniente de imágenes. Hemos presentado dos posibles aplicaciones de nuestro modelo junto con los resultados obtenidos, probando diferentes parámetros y demostrando su utilidad en el campo de la segmentación de imágenes. Como experimento inicial los resultados obtenidos son prometedores, pero debemos realizar más experimentos, con un estudio más profundo de los diferentes parámetros para confirmar los resultados presentados. Debemos estudiar otras medidas de distancia, así como poner a prueba nuestro método con otros conjuntos de datos y espacios de color.

## ACKNOWLEDGMENT

Este trabajo ha sido parcialmente financiado por el proyecto TIN2016-77356-P y por el Servicio de Investigación Universidad Pública de Navarra.

## REFERENCES

- [1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *ImageNet Classif. with Deep Convolutional Neural Networks*, pp. 1097–1105, 2012.
- [2] J. Benediktsson and P. Swain, "Consensus theoretic classification methods," *IEEE Trans. Syst. Man. Cybern.*, vol. 22, no. 4, pp. 688–704, 1992.
- [3] M. Wachowiak, R. Smolikova, Y. Zheng, J. Zurada, and A. Elmaghraby, "An Approach to Multimodal Biomedical Image Registration Utilizing Particle Swarm Optimization," *IEEE Trans. Evol. Comput.*, vol. 8, no. 3, pp. 289–301, jun 2004.
- [4] M. Dorigo, V. Maniezzo, and A. Colomi, "Ant system: optimization by a colony of cooperating agents," *IEEE Trans. Syst. Man Cybern. Part B*, vol. 26, no. 1, pp. 29–41, 1996.
- [5] I. Newton, "Philosophiae Naturalis Principia Mathematica," *Pan*, p. 510, 1687.
- [6] W. E. Wright, "Gravitational clustering," *Pattern Recognit.*, vol. 9, no. 3, pp. 151–166, 1977.
- [7] J. Gomez, D. Dasgupta, and O. Nasraoui, "A New Gravitational Clustering Algorithm," in *Proc. 2003 SIAM Int. Conf. Data Min.* Philadelphia, PA: Society for Industrial and Applied Mathematics, may 2003, pp. 83–94.
- [8] E. Rashedi, H. Nezamabadi-pour, and S. Saryazdi, "GSA: A Gravitational Search Algorithm," *Inf. Sci. (Ny)*, vol. 179, no. 13, pp. 2232–2248, 2009. [Online]. Available: <http://dx.doi.org/10.1016/j.ins.2009.03.004>
- [9] C. Lopez-Molina, H. Bustince, J. Fernandez, P. Couto, and B. De Baets, "A gravitational approach to edge detection based on triangular norms," *Pattern Recognit.*, vol. 43, no. 11, pp. 3730–3741, 2010.
- [10] X. Ren and J. Malik, "Learning a classification model for segmentation," *Proc. Ninth IEEE Int. Conf. Comput. Vis.*, vol. 1, no. c, pp. 10–17 vol.1, 2003.
- [11] J. J. De Mesquita Sá, A. R. Backes, and P. C. Cortez, "A simplified gravitational model for texture analysis," *J. Math. Imaging Vis.*, vol. 47, no. 1-2, pp. 70–78, 2013.
- [12] C. Tomasi and R. Manduchi, "Bilateral Filtering for Gray and Color Images," *Int. Conf. Comput. Vis.*, pp. 839–846, 1998.
- [13] D. Comaniciu and P. Meer, "Mean shift: A robust approach toward feature space analysis," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 5, pp. 603–619, 2002.
- [14] H. Zhu, F. Meng, J. Cai, and S. Lu, "Beyond pixels: A comprehensive survey from bottom-up to semantic image segmentation and cosegmentation," pp. 12–27, 2016.
- [15] P. Arbeláez, M. Maire, C. Fowlkes, and J. Malik, "Contour Detection and Hierarchical Image Segmentation," *Tpami*, vol. 33, no. 5, pp. 898–916, 2011.
- [16] D. Marr, "Vision," *book*, 1982.
- [17] F. Calderero and F. Marques, "Region merging techniques using information theory statistical measures," *IEEE Trans. Image Process.*, vol. 19, no. 6, pp. 1567–86, 2010.
- [18] P. Arbeláez, "Boundary extraction in natural images using ultrametric contour maps," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2006, 2006.
- [19] S. Beucher, "The Watershed Transformation Applied to Image Segmentation," in *Proc. 10th Pfefferkorn Conf. Signal Image Process. Microsc. Microanal.*, 1992, pp. 299–314.
- [20] P. Soille, *Morphological Image Analysis*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004.
- [21] J. F. Canny, "A Computational Approach to Edge Detection," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 8, no. 6, pp. 679–698, 1986.
- [22] F. J. Estrada and A. D. Jepson, "Benchmarking Image Segmentation Algorithms," *Int. J. Comput. Vis.*, vol. 85, no. 2, pp. 167–181, nov 2009.
- [23] C. Lopez-Molina, B. De Baets, and H. Bustince, "Quantitative error measures for edge detection," *Pattern Recognit.*, vol. 46, no. 4, pp. 1125–1139, apr 2013.



**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 7:  
DEEP LEARNING







# Time Series Decomposition for Improving the Forecasting Performance of Convolutional Neural Networks\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Iván Méndez-Jiménez  
*Centro de Investigaciones Energéticas  
Medioambientales y Tecnológicas*  
Madrid, Spain  
ivan.mendez@ciemat.es

Miguel Cárdenas-Montes  
*Centro de Investigaciones Energéticas  
Medioambientales y Tecnológicas*  
Madrid, Spain  
miguel.cardenas@ciemat.es

**Abstract**—Time Series forecasting is of high interest in the Big Data ecosystem. A larger data volume accessible in industry and science, and a higher profit from more accurate predictions have generated a growing application of Deep Learning techniques in the Time Series forecasting. In this work, the improvement of the forecasting capacity of Convolutional Neural Networks and Recurrent Neural Networks when using as input the trend, seasonal and remainder time series generated by the Seasonal and Trend decomposition using Loess, instead of the original time series observations, is evaluated. The benchmark used in this work is composed of eight seasonal time series with different lengths and origins. Besides, Convolutional Neural Networks and Recurrent Neural Networks, comparisons with Multilayer Perceptrons are also undertaken. As a consequence, an improvement in the forecasting capacity when replacing the original observations by their decomposition in Convolutional Neural Networks-based forecasting is stated.

**Index Terms**—Time Series Analysis, Deep Learning, Forecasting, Convolutional Neural Networks, Recurrent Neural Networks, Seasonal and Trend Decomposition using Loess



# Comparing Deep Recurrent Networks Based on the MAE Random Sampling, a First Approach\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Andrés Camero, Jamal Toutouh, Enrique Alba  
*Departamento de Lenguajes y Ciencias de la Computación*  
*Universidad de Málaga*  
Málaga, Spain  
andrescamero@uma.es, {jamal,eat}@lcc.uma.es

**Abstract**—Recurrent neural networks have demonstrated to be good at tackling prediction problems, however due to their high sensitivity to hyper-parameter configuration, finding an appropriate network is a tough task. Automatic hyper-parameter optimization methods have emerged to find the most suitable configuration to a given problem, but these methods are not generally adopted because of their high computational cost. Therefore, in this study we extend the MAE random sampling, a low-cost method to compare single-hidden layer architectures, to multiple-hidden-layer ones. We validate empirically our proposal and show that it is possible to predict and compare the expected performance of an hyper-parameter configuration in a low-cost way.

**Index Terms**—Deep learning, Recurrent neural network, MAE random sampling



# Background modeling for video sequences by stacked denoising autoencoders\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Jorge García-González, Juan M. Ortiz-de-Lazcano-Lobato, Rafael M. Luque-Baena,  
Miguel A. Molina-Cabello, Ezequiel López-Rubio  
*Department of Computer Languages and Computer Science*  
*University of Málaga*  
Málaga, Spain  
{jorgegarcia,jmortiz,rmluque,miguelangel,ezeqlr}@lcc.uma.es

**Abstract**—Nowadays, the analysis and extraction of relevant information in visual data flows is of paramount importance. These images sequences can last for hours, which implies that the model must adapt to all kinds of circumstances so that the performance of the system does not decay over time. In this paper we propose a methodology for background modeling and foreground detection, whose main characteristic is its robustness against stationary noise. Thus, stacked denoising autoencoders are applied to generate a set of robust characteristics for each region or patch of the image, which will be the input of a probabilistic model to determine if that region is background or foreground. The evaluation of a set of heterogeneous sequences results in that, although our proposal is similar to the classical methods existing in the literature, the inclusion of noise in these sequences causes drastic performance drops in the competing methods, while in our case the performance stays or falls slightly.

**Index Terms**—Background modeling, deep learning, autoencoders

# Predicción ordinal de rampas de viento usando *Echo State Networks* de complejidad reducida

M. Dorado-Moreno

Dpto. de Informática y Análisis Numérico  
Universidad de Córdoba  
Córdoba, España  
manuel.dorado@uco.es

P. A. Gutiérrez

Dpto. de Informática y Análisis Numérico  
Universidad de Córdoba  
Córdoba, España  
pagutierrez@uco.es

S. Salcedo-Sanz

Dpto. de Teoría de la Señal y Comunicaciones  
Universidad de Alcalá  
Alcalá de Henares, España  
sancho.salcedo@uah.es

L. Prieto

Dpto. de Recursos Energéticos  
Iberdrola  
Madrid, España

C. Hervás-Martínez

Dpto. de Informática y Análisis Numérico  
Universidad de Córdoba  
Córdoba, España  
chervas@uco.es

**Resumen**—Las *Renovables* son la fuente de energía que más ha crecido en los últimos años a nivel mundial. En particular, la energía eólica en Europa es actualmente la que tiene un mayor crecimiento, estando su capacidad de producción en la segunda posición, por detrás del gas natural. Existen una serie de problemas que complican la integración del recurso eólico en la red eléctrica. Uno de ellos es conocido como rampas de viento, que son incrementos o decrementos de gran magnitud en la velocidad del viento en un tiempo reducido. Estas rampas de viento pueden dañar las turbinas en los parques eólicos, así como reducir los ingresos generados a partir de la producción del parque. Actualmente, la mejor forma de afrontar este problema es predecir estas rampas de viento, de forma que se puedan parar las turbinas con suficiente antelación, evitando así los daños que puedan producirse. Para realizar esta predicción, se suelen utilizar modelos que puedan aprovechar la información temporal. Uno de los modelos más conocidos con estas características son las redes neuronales recurrentes. En este trabajo utilizaremos las conocidas como *Echo State Networks* (ESNs), las cuales han demostrado obtener un buen rendimiento en predicción de series temporales. En concreto, proponemos utilizar ESNs de complejidad reducida para afrontar un problema de predicción de rampas de viento en tres parques eólicos en España. A nivel metodológico, se comparan tres arquitecturas diferentes de red, dependiendo de la configuración de las conexiones de la capa de entrada con el *reservoir* o directamente con la capa de salida. Los resultados muestran que, por lo general, los mejores resultados son obtenidos por la estructura *Delay Line Reservoir with Feedback* (DLRB) y que el aumento en el rendimiento obtenido por la arquitectura de Doble *reservoir* con respecto a la arquitectura de Simple *reservoir* es mínima, y teniendo en cuenta el gran aumento de complejidad computacional de la arquitectura Doble, concluimos que los mejores resultados son obtenidos por la combinación de la estructura DLRB con la arquitectura Simple.

**Index Terms**—Echo state networks; Energía eólica; Clasificación ordinal; Rampas de viento; Redes neuronales recurrentes.

## I. INTRODUCCIÓN

La naturaleza nos ofrece múltiples formas de generar energía de forma sostenible y libres de emisiones contaminantes. Este tipo de energías explotan recursos naturales renovables y actualmente son las que más están creciendo a nivel mundial. Algunas de las más conocidas son la energía solar, la eólica y la marina (mareomotriz, undimotriz, eólica *offshore*), así como sus combinaciones, aunque existen otras alternativas tales como la biomasa o la energía hidráulica. Nuestro trabajo se centrará en este caso en la energía eólica y, dentro de esta, en la producción en parques eólicos, los cuales, generan energía mediante turbinas eólicas de grandes dimensiones. El problema de la gran mayoría de los recursos renovables es que normalmente son intrínsecamente intermitentes, lo que dificulta la completa explotación del recurso, y su incorporación al *mix* energético en igualdad de condiciones con respecto a otros tipos de recursos no renovables. En el caso de la energía eólica, además de su intermitencia intrínseca, aparecen otro tipo de problemas en producción, relacionados con características específicas del recurso. En el caso de los parques eólicos, uno de los problemas más grave son las conocidas como *rampas de viento*, definidas como incrementos o decrementos en la velocidad del viento de gran magnitud en un corto periodo de tiempo. Estas rampas de viento pueden ser positivas, es decir, que se produce un incremento de la velocidad del viento, o negativas, cuando es un decremento. El efecto de las rampas positivas en un parque eólico es, principalmente, el posible daño que pueden causar a las turbinas existentes. Esto puede derivar en un aumento de los costes de mantenimiento del parque. En cuanto a las rampas negativas, su efecto fundamental es un decremento de producción de energía súbito, que puede acarrear problemas

Este trabajo ha sido desarrollado con la financiación de los proyectos TIN2017-85887-C2-1-P, TIN2017-85887-C2-2-P y TIN2017-90567-REDT del Ministerio de Economía y Competitividad de España (MINECO) y fondos FEDER. La investigación de Manuel Dorado-Moreno ha sido financiada por el programa predoctoral FPU (Ministerio de Educación y Ciencia) con referencia FPU15/00647. Los autores agradecen a NVIDIA Corporation la cesión de recursos computacionales a través del GPU Grant Program.



de abastecimiento si este tipo de sucesos no se predice con suficiente antelación.

Muy diversos problemas relacionados con energías renovables han sido abordados mediante técnicas de aprendizaje automático, por ejemplo, en energía solar [2], undimotriz [8] o energía eólica [4]–[6]. En aprendizaje automático, uno de los modelos más conocidos a la hora de tratar con series temporales y realizar predicciones son las redes neuronales recurrentes [12]. La diferencia con las redes neuronales convencionales es la inclusión de ciclos entre sus neuronas, es decir, se permiten conexiones de una neurona consigo misma y con neuronas situadas en las capas anteriores o en su misma capa. De cualquier forma, al incrementar el número de capas (o neuronas) de las redes recurrentes para incrementar su capacidad de cómputo, las redes sufren un problema conocido como desvanecimiento del gradiente [12], debido al cual, al ir enlazando las derivadas a través de los ciclos, estas tienden a cero, por lo que no aportan información al gradiente e impiden la actualización de los pesos. Una de las propuestas más aceptadas para solventar este problema son las *echo state networks* (ESNs) [11], las cuales tienen una capa oculta conocida como *reservoir* en la que se encuentran todos los ciclos de los enlaces entre las neuronas, inicializados de forma aleatoria. Este *reservoir* está totalmente conectado con las entradas y las salidas, y estas últimas conexiones son las únicas que se entrenan. Así, se evita el problema de la tendencia del gradiente a 0, ya que no es necesario utilizar las derivadas para entrenar los pesos del *reservoir*.

Una de las dificultades asociadas a las ESNs es su naturaleza estocástica, ya que parte de su rendimiento depende del azar. Para solventar este problema, en este trabajo vamos a utilizar las ESNs de complejidad reducida propuestas en [14], las cuales establecen los enlaces entre las neuronas siguiendo un patrón razonable y además los inicializan de forma determinista, pudiendo así, justificar su correcto funcionamiento. Además proponemos tres arquitecturas distintas, siguiendo el trabajo realizado en [5], para comprobar las distintas formas en las que el *reservoir* afecta al resultado del modelo dependiendo de las entradas que se conecten a él. Es importante destacar que, debido al orden natural que muestran las distintas categorías a predecir (rampa negativa, ausencia de rampa y rampa positiva), el problema se aborda desde la perspectiva de la clasificación ordinal [10]. Por último, cabe destacar que para este trabajo se utilizarán dos fuentes de datos, a partir de las cuales extraeremos las variables de entrada utilizadas por las ESNs para la predicción de las rampas de viento. La primera incluye mediciones recogidas por los sensores de tres parques eólicos situados en España (ver Figura 1), mientras que la segunda se corresponde a datos generados a través de modelos físicos y matemáticos que son conocidos como datos de reanálisis [7]. Estos datos de reanálisis son muy fiables y se calculan a lo largo de todo el mundo cada 0,125 grados (en latitud y longitud) y cada 6 horas, alcanzando así una buena resolución tanto espacial como temporal.

En la Sección II se expondrán las características extraídas de las dos bases de datos y se explicará la generación de la

base de datos conjunta. Las distintas arquitecturas propuestas para el modelado se expondrán en la Sección III, justo antes de explicar el diseño experimental en la Sección IV. Para concluir, en la Sección V, se mostrarán los resultados obtenidos y se realizará una discusión de los mismos. La Sección VI expondrá las conclusiones obtenidas tras este trabajo.

## II. BASE DE DATOS

En esta sección se explican las características de las fuentes de información utilizadas para resolver el problema de la predicción de rampas de viento, las transformaciones llevadas a cabo y la unión de ambas fuentes de información. La primera fuente de información corresponde a medidas de la velocidad de viento, obtenidas cada hora en tres parques eólicos situados en España, como se puede observar en la Figura 1. Calcularemos las rampas de viento como valores objetivo a ser predichos utilizando distintas variables predictivas. La segunda fuente de información de la que obtendremos variables predictivas es el proyecto de reanálisis ERA-Interim [7], que almacena información sobre el clima cada 6 horas. Estos datos se calculan utilizando modelos físicos, es decir, que no dependen de ningún sensor que pueda generar datos perdidos, por lo que se pueden estimar valores futuros de estos modelos para predecir las rampas de viento.

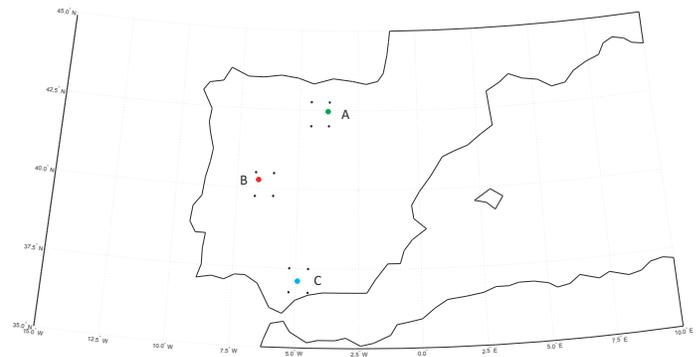


Figura 1: Localización de las tres parques eólicos (A, B y C) y de los nodos de reanálisis considerados en las cercanías de cada parque.

### II-A. Definición de Rampa de Viento

La función  $S_t : \mathbb{R}^k \rightarrow \mathbb{R}$  será la función evaluada para decidir si se ha producido una rampa de viento, o no, en un determinado periodo de tiempo, donde  $k$  será el número de características a considerar. Hay muchas definiciones de  $S_t$  [9] y todas de ellas incluyen la producción de energía ( $P_t$ ) como un criterio del parque eólico o la turbina de viento a considerar. En este artículo utilizamos la siguiente definición:

$$S_t = P_t - P_{t-\Delta t_r},$$

donde  $\Delta t_r$  es el intervalo de tiempo considerado para estudiar la rampa (6 horas en nuestro caso, de acuerdo con la frecuencia de los datos de reanálisis).

Utilizando  $S_t$ , podemos definir el problema de clasificación definiendo un umbral ( $S_0$ ) para discretizar la variable objetivo de la siguiente forma:

$$y_t = \begin{cases} C_{NR}, & \text{si } S_t \leq -S_0, \\ C_{NoR}, & \text{si } -S_0 < S_t < S_0, \\ C_{PR}, & \text{si } S_t \geq S_0. \end{cases}$$

donde  $\{C_{NR}, C_{NoR}, C_{PR}\}$  son las diferentes categorías de eventos a detectar, es decir, rampas negativas (NRs), no rampas (NoRs) y rampas positivas (PRs).

En nuestro caso,  $S_0$  se ha definido como un porcentaje de la capacidad de producción de energía del parque eólico (en concreto, un 50 % siguiendo [9]). La predicción de rampas de viento también implica un vector de variables predictivas: utilizaremos datos de reanálisis climatológicos como datos de entrada ( $\mathbf{z}$ ) (definidos en la siguiente sección), junto con el valor de la velocidad de viento medido por los sensores del parque eólico en el instante anterior al que queremos predecir.

### II-B. Datos de reanálisis

Para cada una de los tres parques, tenemos 48 predictores, que corresponden a 12 variables por cada nodo de reanálisis (considerando los 4 nodos más cercanos a la parque eólico, ver Figura 1). Estos nodos están situados cada 15 kilómetros (0.125 grados) en todo el mundo y en esas localizaciones se calculan las variables de reanálisis utilizando modelos físicos que estiman medidas de variables meteorológicas a muy diferentes alturas. Entre las mismas, tenemos la velocidad de viento, presión y temperatura del aire. Para evitar trabajar con tantos datos, que en muchos casos estarán altamente correlados, por lo que introducirán ruido al modelo, realizamos una media ponderada por la distancia de cada nodo de reanálisis al centro del parque eólico. De esta forma reducimos el número de predictores de reanálisis a 12, sin perder la información relativa de cada nodo. Así, en primer lugar calculamos la distancia de cada nodo de reanálisis al parque eólico mediante la distancia de Haversine:

$$d(p_0, p_j) = \arccos(\sin(lat_0) \cdot \sin(lat_j) \cdot \cos(lon_0 - lon_j) + \cos(lat_0) \cdot \cos(lat_j)),$$

donde  $p_0$  es la localización del parque eólico,  $p_j$  la localización de cada nodo de reanálisis, y  $lat$  y  $lon$  serán la latitud y longitud de los puntos, respectivamente. Una vez que la distancia de cada uno de los nodos de reanálisis (los cuatro puntos negros que rodean a cada parque eólico, ver de nuevo Figura 1) al parque eólico ha sido calculada, estas distancias se invierten y normalizan, considerando que cuanto más corta sea la distancia, más grande será el peso de la información de ese nodo de reanálisis en la media ponderada:

$$w_i = \frac{\sum_{j=1}^4 d(p_0, p_j)}{d(p_0, p_i)}, \quad i = 1, \dots, 4. \quad (1)$$

Después de calcular estos pesos, se utilizan para obtener una media ponderada de cada una de las 12 variables:

$$\bar{z}_i = \sum_{j=1}^4 w_j z_{i,j} \quad i \in \{0, 1, \dots, 11\}$$

siendo  $i$  el índice de cada una de las variables de reanálisis,  $j$  cada uno de los nodos de reanálisis y  $w_j$  el peso correspondiente, calculado en la Ecuación (1).

### III. ARQUITECTURAS PROPUESTAS

En este artículo proponemos una modificación de los modelos utilizados en [5]: en lugar de realizar una clasificación binaria, vamos a resolver un problema de clasificación ordinal para tres clases. Por otra parte, vamos a modificar la estructura del *reservoir* basándonos en las distintas estructuras propuestas en [14], las cuales reducen la complejidad del *reservoir* además de eliminar la aleatoriedad en la inicialización de los mismos, sin reducir de forma considerable el rendimiento del modelo. Gracias a estas estructuras de *reservoir* de complejidad reducida, se construyen los ciclos entre las neuronas del *reservoir* de forma determinista, además de otorgarle a la red una capacidad de memoria óptima para cada problema. Un esquema de las tres estructuras de *reservoir* puede analizarse en la Figura 2. En la capa de salida utilizaremos un modelo de regresión logística ordinal basado en umbrales [13], el cual proyecta los patrones en una dimensión y optimiza el valor de los umbrales para separar las distintas clases.

A continuación describiremos las arquitecturas propuestas para resolver la predicción de rampas de viento, que exploran distintas formas de combinar los valores pasados de la velocidad de viento y los datos de reanálisis procedentes del proyecto ERA-Interim. Proponemos tres arquitecturas, la primera (ver Figura 3a) tiene un único *reservoir* cuya entrada es la velocidad de viento recogida en cada parque eólico en el instante anterior al que se quiere predecir, de forma que el resto de variables de reanálisis se utilizarán directamente como entradas a la capa de salida, sin ser procesadas por ningún *reservoir*. La segunda arquitectura (ver Figura 3b) dispone de dos *reservoir* independientes, uno para la velocidad del viento y otro cuyas entradas serán todas las variables de reanálisis. Por último, proponemos una tercera arquitectura (ver Figura 3c) en la que solo disponemos de un *reservoir* cuyas entradas englobarán tanto la velocidad del viento como el resto de variables de reanálisis. Con estas tres arquitecturas, estudiaremos la capacidad de cómputo del *reservoir* así como su utilidad para cada tipo de variables.

En la capa de entrada, incluimos los vectores de entrada con la velocidad de viento y las 12 variables de reanálisis en los instantes  $t$  (para la primera) y  $t + 1$  (para las demás), respectivamente. El uso de  $\mathbf{z}_{t+1}$  en la capa de entrada para predecir  $y_{t+1}$  es posible, como se ha mencionado en la sección II, debido a que estos datos se calculan mediante modelos físicos que permiten estimarlos de forma fiable 6 horas después del instante actual.

La metodología propuesta para entrenar los distintos modelos propuestos es la siguiente:

1. Crear un *reservoir* de tamaño  $M$ , conectando sus neuronas según las restricciones de cada tipo de *reservoir* (DLR, DLRB y SCR) tal y como se indica en [14].
2. Recoger todos los estados del *reservoir*. Para ello, se alimenta el *reservoir* desde el instante  $t = 1$  hasta el

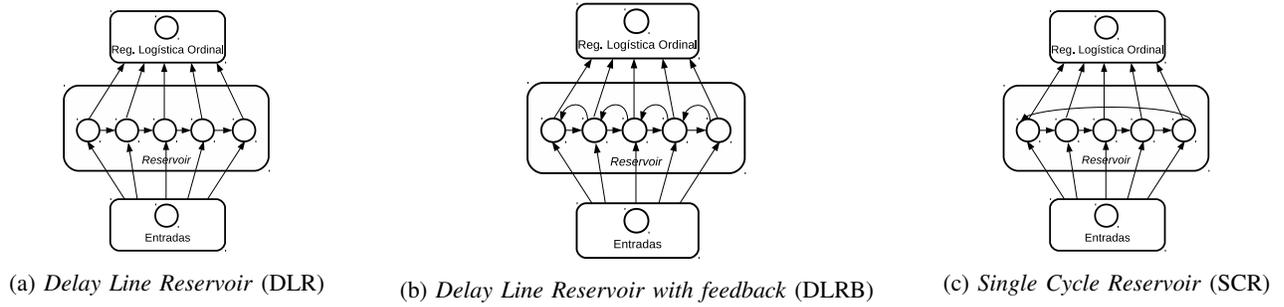
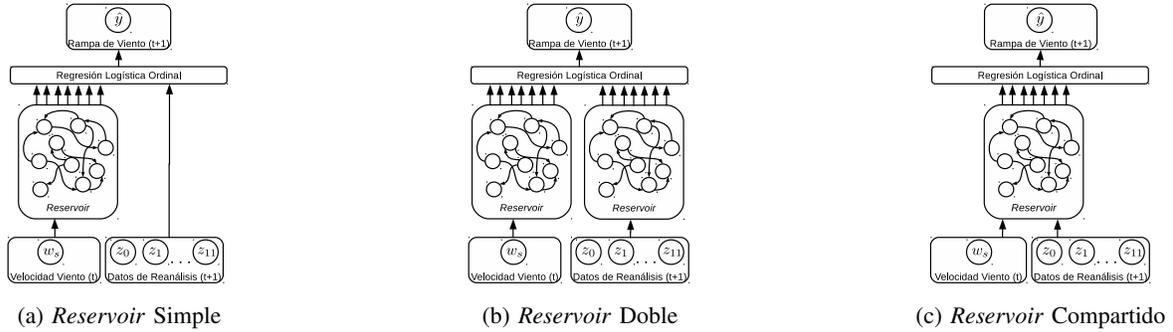

 Figura 2: Estructuras de *reservoir* consideradas


Figura 3: Distintas arquitecturas de red propuestas

instante  $t = M$ , de forma tal que todas las conexiones del *reservoir* hayan recibido una señal, permitiendo obtener el vector  $\mathbf{x}_t$  completo.

3. Combinar los estados del *reservoir* ( $\mathbf{x}_t$ ) y/o las variables de reanálisis ( $\mathbf{z}_{t+1}$ ).
4. Calcular los pesos de salida entrenando un modelo de regresión logística ordinal, proyectando los patrones sobre una recta y estableciendo los umbrales para distinguir cada una de las tres clases ( $C_{NR}$ ,  $C_{NoR}$  y  $C_{PR}$ ).

Una vez que la red ha sido entrenada, se puede utilizar para la predicción en tiempo real de rampas de viento, descartando el patrón correspondiente a  $t = 0$  ya que no habría información de instantes anteriores de tiempo para poder predecirlo.

#### IV. DISEÑO EXPERIMENTAL

En esta sección se describen los experimentos que se han llevado a cabo para comparar las distintas arquitecturas propuestas en la Sección III.

##### IV-A. Métricas de evaluación

Hay muchas métricas que pueden ser utilizadas para evaluar clasificadores ordinales. Las más comunes en aprendizaje automático son el Error Absoluto Medio (*MAE*) y el Error Medio Cero-uno (*MZE*) [10], siendo  $MZE = 1 - Acc$ , donde *Acc* es la precisión o la proporción de patrones bien clasificados. De cualquier modo, estas métricas podrían no ser las mejores opciones, por ejemplo, cuando medimos el rendimiento en bases de datos desequilibradas (como es nuestro caso, ver Tabla I) [1], y/o cuando los costes de diferentes

errores varían notablemente. Es por ello que, para poder evaluar correctamente el rendimiento de los clasificadores, hemos incluido la media geométrica de las sensibilidades (*GMS*), que es una métrica más estricta a la hora de penalizar la mala clasificación de las clases minoritarias, siendo 0 cuando una de las clases está mal clasificada por completo. Así, hemos considerado 3 métricas para evaluar estos modelos:

- La proporción de patrones bien clasificados (*CCR*) que se define como:

$$CCR = \frac{1}{N} \sum_{i=1}^N (I(y_i^* = y_i)),$$

donde  $I(\cdot)$  es la función de pérdida cero-uno,  $y_i$  es la salida deseada para el patrón  $\mathbf{x}_i$ ,  $y_i^*$  es la predicción del modelo y  $N$  es el número de patrones del conjunto de entrenamiento o *test* en la base de datos. Los valores del *CCR* varían de 0 a 1 y representa el rendimiento global de la tarea de clasificación.

- Las sensibilidades de cada clase representan la habilidad del modelo para predecir correctamente cada tipo de evento:

$$S_{NR} = \frac{CC_{NR}}{N_{NR}}, \quad S_{NoR} = \frac{CC_{NoR}}{N_{NoR}}, \quad S_{PR} = \frac{CC_{PR}}{N_{PR}},$$

donde  $CC_{NR}$ ,  $CC_{NoR}$  y  $CC_{PR}$  es el número de eventos de tipo *NR*, *NoR* y *PR* bien clasificados y  $N_{NR}$ ,  $N_{NoR}$  y  $N_{PR}$  ( $N_{NR} + N_{NoR} + N_{PR} = N$ ) es el número total de eventos de tipo *NR*, *NoR* y *PR*. La media geométrica de las sensibilidades (*GMS*) se define como:

$$GMS = \sqrt[3]{S_{NR} \cdot S_{NoR} \cdot S_{PR}}.$$

Incluimos esta métrica debido al alto desequilibrio de la base de datos, de forma que los clasificadores que no se centren en una de las clases sean fácilmente detectables, ya que su  $GMS$  será cercano a 0.

- La media del error absoluto medio ( $AMAE$ ) [1] es la media del error de clasificación  $MAE$  en cada clase, donde  $MAE$  es la media de la desviación absoluta entre la clase predicha y la clase real. Esta métrica es capaz de mitigar el efecto de las distribuciones de clase desequilibradas y se define como:

$$AMAE = \frac{1}{J} \sum_{j=1}^J MAE_j,$$

donde

$$MAE_j = \frac{1}{N_j} \sum_{i=1}^{N_j} |\mathcal{O}(y_i) - \mathcal{O}(y_i^*)|,$$

donde  $1 \leq j \leq J$ ,  $\mathcal{O}(C_{NR}) = 1$ ,  $\mathcal{O}(C_{NoR}) = 2$ ,  $\mathcal{O}(C_{PR}) = 3$ . Los valores de  $MAE$  van desde 0 hasta  $J - 1$ , al igual que los de  $AMAE$ . En nuestro caso tendremos  $J = 3$ .

#### IV-B. Diseño Experimental

Los tres parques eólicos de la Figura 1 se han utilizado en la comparación de resultados de las distintas arquitecturas propuestas. Para evaluar los resultados, las tres bases de datos se han dividido de la misma forma: los últimos 365 días son utilizados para el conjunto de test y el resto de la base de datos para el conjunto de entrenamiento. Todas las bases de datos comienzan el 2/3/2002 y finalizan el 29/10/2012. Con esta partición de los datos, los patrones por clase de cada una de las tres bases de datos se muestra en la Tabla I, especificando el tipo de evento recogido (rampa negativa, NR, no rampa, NoR, y rampa positiva, PR).

Tabla I: Número de patrones por clase de las distintas bases de datos consideradas en la experimentación

Parque	Conjunto	#NR	#NoR	#PR
A	Entrenamiento	753	12469	886
	Test	67	1288	105
B	Entrenamiento	1161	11804	1074
	Test	117	1220	123
C	Entrenamiento	661	12768	679
	Test	58	1340	62

Las diferentes arquitecturas presentadas en la sección III han sido comparadas entre si, comparando además las distintas estructuras internas del *reservoir* de acuerdo a [14]. Deseamos identificar la arquitectura con mejor rendimiento y comprobar si el *reservoir* de complejidad reducida es suficiente para nuestro problema.

Debido al desequilibrio del problema, realizamos un sobre-muestreo mediante la metodología SMOTE [3] a las salidas del *reservoir*, tal y como se explica y justifica en [4]. Para

cada clase minoritaria ( $C_{NR}$  y  $C_{PR}$ ), generaremos tantos patrones sintéticos como se indique mediante una proporción del número de patrones de la clase mayoritaria (en nuestro caso, un 60% de los patrones de la clase mayoritaria), evitando así obtener clasificadores triviales. El sobre-muestreo se realiza únicamente sobre el conjunto de entrenamiento.

Si no se controlan los pesos de la regresión logística ordinal, estos pueden llegar a ser muy grandes, sobre-ajustando la red o impidiendo clasificar los patrones de las clase minoritarias. Para paliar este efecto, incluimos un término de regularización, que obliga a ajustar un parámetro  $\alpha$  que controla su importancia. Este parámetro ha sido ajustado mediante una validación cruzada interna de tipo *5-fold* sobre el conjunto de entrenamiento. Los valores explorados han sido  $\alpha \in \{2^{-5}, 2^4, \dots, 2^{-1}\}$ . La selección final del mejor valor se realiza en base a maximizar la mínima sensibilidad, es decir,  $MS = \min\{S_{NR}, S_{NoR}, S_{PR}\}$ .

El resto de parámetros se han configurado de la siguiente forma: el número de neuronas del *reservoir* es  $M = 50$ , asumiendo que es un tamaño suficiente para abordar el problema sin suponer un coste computacional demasiado alto. Los valores de los enlaces del *reservoir* se establecen según una distribución uniforme entre los valores  $[-0,9, 0,9]$ .

#### V. RESULTADOS

Esta sección expone y discute los resultados obtenidos por las distintas arquitecturas de red y las diferentes estructuras de *reservoir* propuestas. En la Tabla II, se pueden observar los resultados de las tres arquitecturas con el *reservoir* de estructura DLR, en la Tabla III los resultados con la estructura DLRB y en la Tabla IV los resultados obtenidos usando la estructura SCR (ver Figuras 2a, 2b y 2c, respectivamente).

Tabla II: Resultados obtenidos con las tres arquitecturas propuestas con estructura DLR

Parque	Modelo	GMS	AMAE	CCR	MS
A	Simple	<i>0,6607</i>	<i>0,3485</i>	0,7212	<i>0,5671</i>
	Doble	<b>0,6951</b>	<b>0,3060</b>	<b>0,7411</b>	<b>0,5820</b>
	Compartido	0,3056	0,6207	<i>0,7328</i>	0,1791
B	Simple	<b>0,6394</b>	<b>0,3850</b>	<i>0,7082</i>	<b>0,5811</b>
	Doble	<i>0,6311</i>	<i>0,3903</i>	0,7000	<i>0,5726</i>
	Compartido	0,3185	0,5921	<b>0,7630</b>	0,0813
C	Simple	<b>0,6344</b>	<b>0,3768</b>	0,7383	<i>0,5689</i>
	Doble	<i>0,6227</i>	<i>0,3931</i>	<i>0,7452</i>	<b>0,5862</b>
	Compartido	0,2443	0,6598	<b>0,7636</b>	0,0967

El mejor resultado se muestra en negrita y el segundo mejor en cursiva

Tal y como se observa en la Tabla II, la arquitectura simple gana en dos de los tres parques eólicos, la doble gana en uno y la compartida obtiene los peores resultados. Como se ha comentado anteriormente en la sección IV-A, se obtiene un alto valor de  $CCR$  pero a coste de un valor muy bajo de  $GMS$ , clasificando incorrectamente las clases minoritarias.

Por el contrario, en la Tabla III, la arquitectura con *reservoir* doble gana en dos de los tres parques eólicos, mientras que la arquitectura con un único *reservoir* para la velocidad de



Tabla III: Resultados obtenidos con las tres arquitecturas propuestas con estructura DLRB

Parque	Modelo	GMS	MAAE	CCR	MS
A	Simple	<i>0,6715</i>	0,3389	0,7294	<i>0,5970</i>
	Doble	<b>0,6971</b>	<b>0,3057</b>	<i>0,7397</i>	<b>0,6268</b>
	Compartido	0,3630	0,5484	<b>0,7863</b>	0,1343
B	Simple	<b>0,6397</b>	<b>0,3847</b>	<i>0,7089</i>	<b>0,5726</b>
	Doble	<i>0,6352</i>	<i>0,3912</i>	0,7006	<i>0,5470</i>
	Compartido	0,1648	0,6634	<b>0,7821</b>	0,0427
C	Simple	<i>0,6290</i>	<i>0,3871</i>	0,7376	<i>0,5645</i>
	Doble	<b>0,6437</b>	<b>0,3733</b>	<i>0,7486</i>	<b>0,5862</b>
	Compartido	0,1922	0,6454	<b>0,8445</b>	0,0645

El mejor resultado se muestra en negrita y el segundo mejor en cursiva

viento obtiene el segundo resultado en estos dos parques y el mejor resultado en el restante. El mal comportamiento de la arquitectura con *reservoir* compartido se repite.

Tabla IV: Resultados obtenidos con las tres arquitecturas propuestas con estructura SCR

Parque	Modelo	GMS	MAAE	CCR	MS
A	Simple	<i>0,6607</i>	0,3485	0,7212	<i>0,5671</i>
	Doble	<b>0,6951</b>	<b>0,3060</b>	<b>0,7411</b>	<b>0,5970</b>
	Compartido	0,3056	0,6207	<i>0,7328</i>	0,1492
B	Simple	<b>0,6394</b>	<b>0,3850</b>	<i>0,7082</i>	<b>0,5726</b>
	Doble	<i>0,6311</i>	<i>0,3903</i>	0,7000	<i>0,5641</i>
	Compartido	0,3185	0,5921	<b>0,7630</b>	0,1623
C	Simple	<b>0,6344</b>	<b>0,3768</b>	<i>0,7383</i>	<b>0,5689</b>
	Doble	<i>0,6227</i>	<i>0,3931</i>	<i>0,7383</i>	<i>0,5517</i>
	Compartido	0,2443	0,6598	<b>0,7636</b>	0,1290

El mejor resultado se muestra en negrita y el segundo mejor en cursiva

Por último, los resultados obtenidos con la estructura SCR, que podemos observar en la Tabla IV, siguen la misma dirección que los obtenidos con la estructura DLR, lo que indica que en dos de las tres bases de datos el modelo simple obtiene los mejores resultados.

Comparando las tres tablas, la estructura de *reservoir* que mejor rendimiento obtiene para la predicción de rampas de viento es la DLRB. A su vez, la arquitectura de *reservoir* doble solo mejora los resultados para la estructura DLRB (y no para las otras dos). Si consideramos el incremento de complejidad que se introduce en el entrenamiento de la regresión logística ordinal (62 entradas para el modelo simple frente a 100 entradas para el modelo doble), podemos afirmar que la arquitectura de *reservoir* simple es la más adecuada para este problema.

## VI. CONCLUSIONES

Este artículo propone y evalúa tres arquitecturas distintas de redes recurrentes, y cada una de estas tres arquitecturas se crea con una estructura diferente de *reservoir* de complejidad reducida. Estas propuestas se utilizan para realizar una predicción ordinal en tres clases de rampas de viento, donde también se considera el alto nivel de desequilibrio de la base de datos.

Las arquitecturas propuestas cambian la forma en que se procesan los datos de entrada, que son una combinación de la velocidad del tiempo medida en el parque eólico y 12 variables de reanálisis. Por una parte tenemos solo la velocidad de viento (medida en cada parque eólico) procesada por el *reservoir* mientras que todas las variables de reanálisis se introducen directamente en la regresión logística ordinal. Otra de las arquitecturas dispone de dos estructuras de *reservoir*, una para procesar la velocidad del viento y otra para procesar las variables de reanálisis. La última dispone de un único *reservoir* para procesar todas las entradas.

Para evitar los modelos triviales (que clasifican todo en la clase mayoritaria), hemos aplicado sobre-muestreo a las activaciones del *reservoir*, mejorando así los resultados. Podemos concluir que el modelo con un único *reservoir* para la velocidad de viento obtiene el mejor rendimiento, siendo pocos los casos en los que la arquitectura de doble *reservoir* funciona mejor que la simple. Con respecto a las estructuras de *reservoir* de complejidad reducida que han sido comparadas, los mejores resultados se obtienen con la estructura *Delay Line Reservoir with feedback*.

## REFERENCIAS

- [1] S. Baccianella, A. Esuli, F. Sebastiani, Evaluation measures for ordinal regression, in: Proc. of the 9th Int. Conf. on Intelligent Systems Design and Apps, pp. 283-287 (2009).
- [2] S. Basterrech and T. Buriánek, "Solar irradiance estimation using the Echo State Network and the flexible neural tree," *Intelligent data analysis and its Applications, Volume 1*, Springer, pp. 475-484 (2014).
- [3] N. V. Chawla, K. W. Bowyer, L. O. Hall, W. P. Kegelmeyer, "SMOTE: synthetic minority over-sampling technique," *Journal of artificial intelligence research* vol. 16, pp. 321-357 (2002).
- [4] M. Dorado-Moreno, A.M. Durán-Rosal, D. Guijo-Rubio, P.A. Gutiérrez, L. Prieto, S. Salcedo-Sanz and C. Hervás-Martínez, "Multiclass Prediction of Wind Power Ramp Events Combining Reservoir Computing and Support Vector Machines," *Conference of the Spanish Association for Artificial Intelligence, Lecture Notes in Computer Science*, vol. 9868, pp. 300-309 (2016).
- [5] M. Dorado-Moreno, L. Cornejo-Bueno, P.A. Gutiérrez, L. Prieto, S. Salcedo-Sanz and C. Hervás-Martínez, "Combining *reservoir* computing and over-sampling for ordinal wind power ramp prediction," *International Work-conference on Artificial Neural Networks, Lecture Notes in Computer Science*, vol. 10305, pp. 708-719 (2017).
- [6] M. Dorado-Moreno, L. Cornejo-Bueno, P.A. Gutiérrez, L. Prieto, C. Hervás-Martínez and S. Salcedo-Sanz, "Robust estimation of wind power ramp events with *reservoir* computing," *Renewable Energy*, vol. 111, pp. 428-437 (2017).
- [7] D. P. Dee, S. M. Uppala, A. J. Simmons, P. Berrisford, P. Poli et al., "The ERA-Interim reanalysis: configuration and performance of the data assimilation system," *Quart. J. of the Royal Met. Society*, vol. 137, pp. 553-597 (2011).
- [8] J. C. Fernandez, S. Salcedo-Sanz, P. A. Gutiérrez, E. Alexandre y C. Hervás-Martínez. "Significant wave height and energy flux range forecast with machine learning classifiers," *Engineering Applications of Artificial Intelligence*, vol. 43, pp. 44-53 (2015).
- [9] C. Gallego-Castillo, A. Cuerva-Tejero and O. López-García, "A review on the recent history of wind power ramp forecasting," *Renewable and Sustainable Energy Rev.*, vol. 52, pp. 1148-1157, (2015).
- [10] Pedro Antonio Gutiérrez, María Pérez-Ortiz, Javier Sánchez-Monedero, Francisco Fernández-Navarro, and César Hervás-Martínez, "Ordinal regression methods: survey and experimental study," *IEEE Trans. on Knowledge and Data Engineering*, vol.28, pp. 127-146 (2016)
- [11] H. Jaeger, "The "echo state" approach to analysing and training recurrent neural networks," *GMD Report 148*, German National Research Center for Information Technology, pp. 1-43, (2001).



- [12] M. Lukosevicius and H. Jaeger, "Reservoir computing approaches to recurrent neural network training," *Computer Science Review*, vol. 3, no. 3, pp. 127-149 (2009).
- [13] P. McCullagh, "Regression Modelos for Ordinal data," *J. of the Royal Statistic Society*, vol. 42, no. 2, pp. 109-142 (1980).
- [14] A. Rodan and P. Tiño, "Minimum Complexity Echo State Network," *IEEE Trans. Neural Networks*, vol. 22, no. 1, pp. 131-144 (2011).



# DetECCIÓN DE VARIEDAD Y ESTADO DE MADURACIÓN DEL CIRUELO JAPONÉS UTILIZANDO IMÁGENES HIPERESPECTRALES Y APRENDIZAJE PROFUNDO

F. Chávez, B. Rodríguez-Puerta, F. J. Rodríguez-Díaz  
Dpto. de Ingeniería en Sistemas Informáticos y Telemáticos  
Universidad de Extremadura  
06800 Mérida, España.  
Email: {fchavez, brpuerta, fjrodriguez}@unex.es

Rafael M. Luque-Baena  
Dpto. de Lenguajes y Ciencias de la Computación  
Universidad de Málaga  
29071, Málaga, España  
Email: rmluque@lcc.uma.es

**Resumen**—En la actualidad, España ocupa el séptimo puesto como productor de ciruelas a nivel mundial y el tercero a nivel europeo según la Organización de las Naciones Unidas para la Alimentación y la Agricultura. La importancia que tiene el cultivo de esta fruta en nuestro país es evidente, siendo mayor en Comunidades Autónomas como la Extremeña, que centran su actividad económica en el sector primario. Lo que debe diferenciar una producción es su calidad, pero la calidad de los frutos tradicionalmente se hace en base a la experiencia de los agricultores y técnicos, basándose únicamente en su percepción visual. Esto puede generar errores en la determinación de la fecha óptima de recolección.

En este trabajo se propone un método novedoso basado en el análisis de imágenes hiperespectrales de los frutos del ciruelo japonés que, mediante técnicas de aprendizaje profundo (Deep Learning) y utilizando para ello redes neuronales convolucionales, se obtienen eficaces clasificadores de los frutos por su variedad y su fecha de maduración. Los resultados presentados en este trabajo permiten afirmar que es posible dotar a los agricultores y técnicos agrícolas de herramientas que les ayuden a la correcta toma de decisión en relación a la fecha de maduración de sus frutos, para poder obtener productos de mayor calidad y ser más competitivos en el sector.

## I. INTRODUCTION

La Organización de las Naciones Unidas para la Alimentación (FAO) sitúa a España como el séptimo productor de ciruelas del mundo y el tercero a nivel europeo<sup>1</sup>. La importancia económica que tiene el cultivo de este fruto en nuestro país es evidente. Si nos centramos en la comunidad autónoma de Extremadura, que es donde se está desarrollando el estudio aquí presentado, el Ministerio de Agricultura, Pesca, Alimentación y Medio Ambiente Español, cifra en 6500Has el territorio dedicado a esta actividad. Una mejora en el proceso de recolección, que puede ser recolectar el fruto en su momento óptimo con las herramientas que aquí se presentan, puede suponer una gran ventaja competitiva de las Empresas Extremeñas sobre sus competidoras.

La calidad de un producto es percibida por el consumidor como un conjunto de atributos que son evaluados de forma subjetiva, con el fin de escoger el mejor. Si nos centramos

en la fruta, esta calidad la mediremos por: apariencia, aroma, sabor, etc. Pero, ¿cómo obtenemos frutas de mayor calidad?, podemos utilizar técnicas para mejorar los procesos de cultivo o recolección del fruto en su momento óptimo. De esta forma, cuando llegue la fruta al consumidor, alcanzará la calidad deseada.

La clasificación de la ciruela por su estado de maduración es un proceso que se realiza de manera manual, lo que puede llevar a clasificaciones erróneas. Este proceso históricamente ha sido realizado por operarios humanos, agricultores o técnicos, que con la experiencia adquirida durante los años de trabajo, son capaces, de manera visual, de clasificar las ciruelas por su calidad. Este método tiene grandes limitaciones ya que las decisiones que se toman dependen en gran medida de la experiencia de éstos. Se trata pues de un método altamente subjetivo, que puede derivar en errores en la cosecha, ya sea por recoger el fruto antes de tiempo o incluso con una fecha posterior a su estado óptimo. Para intentar solucionar este problema y ayudar a los operarios del sector, se están introduciendo nuevas técnicas [1] que tienen como finalidad la de servir de apoyo en la correcta toma de decisiones. Entre estas técnicas novedosas se encuentran las técnicas basadas en visión por computador [3], [4] y algoritmos de *machine learning* [2]. Este tipo de algoritmos requieren de un proceso intensivo de aprendizaje, que una vez concluido, genera potentes clasificadores que ayudarán a los agricultores y técnicos a tomar la decisión más acertada en función a los parámetros óptimos de cosecha.

La correcta clasificación de las ciruelas por su estado de maduración es de gran importancia, debido principalmente a que ciertas propiedades internas del fruto (sólidos solubles, brix, firmeza...) están directamente relacionadas con su estado de maduración. Para poder conocer el estado de estas variables es necesario la utilización de técnicas analíticas en un laboratorio. Los principales inconvenientes de estas técnicas se resumen en la necesidad de la destrucción del fruto para conocer sus propiedades químicas y los complejos y costosos materiales que se utilizan para ello.

La incorporación al proceso de técnicas de *machine learning*

<sup>1</sup><http://www.fao.org/home/en/>

por las industrias alimentarias en los procesos selectivos es habitual [2], aplicando desde bosques aleatorios (*random decision forests*) [5], máquinas de vectores de soporte [6] y redes neuronales en la evaluación de la calidad del producto [7].

El objetivo del trabajo que aquí se presenta es la detección de la variedad de la ciruela en su fase temprana de maduración, así como su estado de maduración. Las variedades seleccionadas en este estudio son:

- Black Splendor
- Angeleno
- OwenT

El análisis de imágenes se realizará a través de imágenes hiperespectrales de las diferentes variedades de ciruelas, divididas en diferentes semanas de maduración. El uso de imágenes hiperespectrales para el análisis de calidad en productos agroalimentarios es ampliamente utilizado [9], [11], obteniendo buenos resultados. Se pretende localizar espectros de frecuencia que nos permitan, a través de las propiedades físico-químicas que describen, clasificar las ciruelas por variedad y maduración. Los resultados serán comparados con técnicas previas donde únicamente se utilizaban imágenes tipo RGB [15].

El resto del trabajo se divide de la siguiente forma: la sección II describe el estado del arte de técnicas similares a las descritas en este trabajo. La sección III describe la metodología que se ha utilizado en este trabajo. Por último, los resultados obtenidos junto con las conclusiones, son presentados en las secciones IV y V, respectivamente.

## II. ESTADO DEL ARTE

Entre los trabajos más destacados en esta línea de investigación se encuentra [1], el cual tiene como objetivo el estudio y detección de la maduración en los frutos con hueso.

La aplicación de técnicas de visión artificial para el análisis de los alimentos ha aumentado considerablemente en los últimos años [2]. La diversidad de las aplicaciones depende, entre otras cosas, del hecho de que los sistemas de visión artificial proporcionan información sustancial acerca de la naturaleza y los atributos de los objetos presentes en una escena. Otra característica importante de tales sistemas es que abren la posibilidad de estudiar estos objetos en las regiones del espectro electromagnético donde el ojo humano es incapaz de operar, como en el ultravioleta (UV), infrarrojo cercano (NIR) o infrarrojo (IR).

Investigadores de todo el mundo han estudiado el potencial de diversas técnicas para conocer la calidad de la fruta [4]. Una de las más utilizadas han sido las diferentes técnicas de espectroscópicas, como la NIR [13]. El éxito de la utilización de estas técnicas reside en las ventajas que aportan a los investigadores, estas son las siguientes:

- El proceso de medición es simple y rápido.
- Se trata de una técnica no destructiva.
- Permiten conocer varias propiedades de la fruta a la vez.

El inconveniente que tienen las técnicas de espectroscopia es que solamente nos aportan información de los componentes

químicos y físicos de la fruta en el punto medido, para poder obtener más información, es necesario combinar esta técnica con la adquisición de imágenes. Por un lado, se tiene la información obtenida de la adquisición de la imagen del fruto, que se trata de una información espacial: morfología, tamaño, etc. Por otro lado, mediante la espectroscopia, se obtiene información sobre los componentes químicos y propiedades físicas que la componen. Sin embargo, si nos centramos en las técnicas espectrales de imágenes, nos permiten la obtención de imágenes de frutas e información espectral simultáneamente, con las ventajas de una alta resolución espectral y múltiples bandas de ondas. De acuerdo con la resolución espectral, la espectroscopia de imágenes se puede dividir en imágenes multiespectrales, imágenes hiperespectrales e imágenes ultra-espectrales. Las imágenes multiespectrales y las imágenes hiperespectrales son factibles para la medición de los parámetros de calidad de la fruta [12].

Una nueva técnica ha surgido en los últimos años con fuerza en el campo del aprendizaje profundo (Deep learning en inglés) [14], se trata de las redes neuronales convolucionales (CNN en inglés) [7]. Estas redes basan su funcionamiento en un aprendizaje jerarquizado en el cual estructuras de alto nivel son construidas de manera automática a partir de estructuras de más bajo nivel llamadas capas, comenzado por los datos sin procesar: los píxeles de una imagen. Deep learning surge como una alternativa frente a una mayoría de técnicas de aprendizaje que están basadas solamente en una o, a lo sumo, dos capas de transformaciones no lineales de características.

El aprendizaje profundo a través de CNNs [14] es una alternativa a los métodos clásicos de clasificación que requieran de una cuidadosa selección de las características realizada a mano. Los métodos clásicos han demostrado ser bastante eficaces para resolver problemas simples o problemas bien delimitados, pero tropiezan con dificultades para hacerlos frente con problemas complejos del mundo real tales como objetos y reconocimiento de voz. Es en estos problemas complejos donde el aprendizaje profundo está resultando ser verdaderamente efectivo, siendo el problema aquí presentado como un problema complejo de visión.

## III. METODOLOGÍA

Será necesaria la generación de un conjunto de imágenes hiperespectrales de los frutos que se van recolectando en diferentes semanas de maduración. Para ello, se requerirá el uso de hardware especializado que nos permita la captura de imágenes de las frutas en un entorno controlado de laboratorio. Así como un software específico de control para todo el hardware, el cual se describe a continuación:

- Cabina de iluminación Matcher Modelo MM-4e equipada con cuatro fuentes de luz: Simulador de luz diurna 6500K y de 5000K y una fuente ultravioleta para medir la fluorescencia si es necesario.
- Cámara hiperespectral Cuber UHD 285. Dicha cámara cuenta con un rango de longitud de onda comprendido entre los 450 - 950 nm con un intervalo de submuestreo cada 4 nm. Los fabricantes garantizan 125 canales de



información hiperespectral, aunque la cámara es capaz de ofrecer hasta los 138 canales.

- Plataforma giratoria diseñada y controlada por arduino para girar 90 grados cada pieza de fruta de forma automática.
- Software diseñado con MatLab para el control semi-automático de la plataforma giratoria y toma de imágenes hiperespectrales.

Para poder entender mejor el aspecto de las frutas capturadas y las mínimas diferencias que existen para el ojo humano, en la Figura 1 podemos observar un conjunto de imágenes RGB de las frutas empleadas en este estudio.

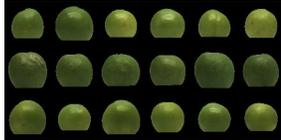


Figura 1. Ejemplo imágenes RGB. Angeleno, Black Splendor y OwentT

Las imágenes que captura la cámara hiperespectral son imágenes tipo CUE, que deben ser post-procesadas para obtener imágenes tipo PNG, utilizadas en este trabajo, que representan las 138 capas del espectro que ofrece la cámara. La Figura 2 muestra un ejemplo de ciertas bandas convertidas a imagen PNG.



Figura 2. Ejemplo imágenes procesadas fichero tipo CUE

Una vez creados los conjuntos de datos correspondientes, se han utilizado técnicas de aprendizaje profundo para generar modelos de clasificación basados en CNNs, en concreto se ha utilizado *Alexnet* [16], que a través de un proceso de optimización, se han obtenido los clasificadores destinados a detectar la variedad y la maduración de los frutos del ciruelo japonés.

El entranamiento de este tipo de redes requiere de una estructura muy específica que posibilita todo el proceso de aprendizaje de la red. En el trabajo aquí presentado se ha utilizado el framework llamado Caffe<sup>2</sup>, que nos permite realizar el proceso de aprendizaje.

Todo proceso estocástico, como el que nos compete en este trabajo, requiere realizar el mismo proceso de aprendizaje un determinado número de veces, para poder consolidar los resultados obtenidos. Para ello, en este trabajo hemos utilizado la técnica llamada K-fold cross validation, donde K=5. Esta técnica nos obliga a dividir el conjunto de imágenes en 5 particiones, donde usará un conjunto compuesto por 4 de estas particiones para entrenar a la red y 1 para validar los resultados. El proceso debe repetirse tantas veces como subconjuntos

<sup>2</sup><http://caffe.berkeleyvision.org>

se hayan realizado, en nuestro caso 5. Posteriormente, con cada subconjunto se repite nuevamente un total de 6 veces para el ajuste de la red, obteniendo así un total de 30 ejecuciones, lo que nos permite consolidar los resultados que arroje la red, a través de la media de los mismos.

#### IV. RESULTADOS

Entre los objetivos citados en este estudio se encuentra el análisis de la información hiperespectral de las imágenes de fruta, para obtener las longitudes de onda más prometedoras para su clasificación por variedad y madurez. Esto nos permitirá desechar gran cantidad de información hiperespectral y centrarnos en las bandas más interesantes que, como se puede ver en esta sección, ofrecen resultados muy robustos en relación a la clasificación de la variedad de la fruta, así como sobre su maduración.

En este apartado se presentan los resultados obtenidos por los diferentes clasificadores que se han optimizado utilizando *Alexnet* como CNN base. La Tabla I muestra una descripción de los los diferentes *datasets* utilizados.

Tabla I  
CARACTERÍSTICAS DE LAS CIRUELAS

<i>Dataset</i>	Número de Imágenes <sup>3</sup>	Fecha de recolección	Semanas de maduración
MW1	121 x 138	9-13 Mayo	6 Angeleno, 7 Owent y 7 BlackSplendor
MW2	147 x 138	23-27 Mayo	8 Angeleno, 9 Owent y 9 BlackSplendor
MW3	127 x 138	13-17 Junio	11 Angeleno, 12 Owent y 12 BlackSplendor
MW4	130 x 138	4-9 of Julio	14 Angeleno, 15 Owent y 15 BlackSplendor
All_MW	525 x 138	-	-

El trabajo que se ha llevado a cabo ha conestado de la optimización de 138 clasificadores diferentes, ya que cada uno de ellos se debía especializar en una de las bandas obtenidas de las imágenes tomadas con la cámara hiperespectral. Para la optimización de este trabajo se ha utilizado un equipo compuesto por una GPU Tesla K20.

A continuación se presentan los resultados obtenidos por los clasificadores especializados en la variedad de la fruta, así como los especializados en la maduración.

##### IV-A. Resultados clasificación por variedad

El objetivo de esta tarea es analizar si en diferentes estados de maduración, podemos encontrar diferentes longitudes de onda que ayuden a la clasificación por variedad de las ciruelas. Se presenta un conjunto de gráficas que resumen el resultado de estos clasificadores, así como se puede observar en cada uno de ellos la presencia de ciertas bandas espectrales que obtienen excelentes resultados de clasificación.

Los resultados presentados en la Fig. 3 se corresponden con las diferentes semanas de maduración indicadas en la Tabla I. Si analizamos los resultados atendiendo a su semana de maduración, puede observarse que para el *dataset MW1* todos

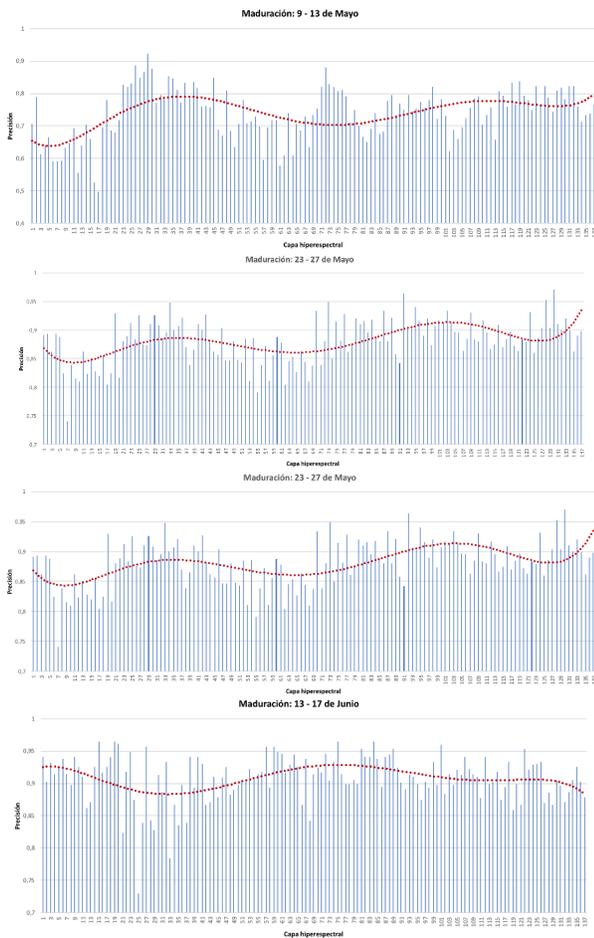


Figura 3. Resultado de clasificación por variedad. *Datasets*: arriba izquierda MW1, arriba derecha MW2, abajo izquierda MW3, abajo derecha MW4

los frutos se encuentran en una etapa muy temprana de su ciclo de maduración. Esto tiene como consecuencia que las ciruelas se encuentran poco desarrolladas y el parecido entre ellas es elevado, independiente de la variedad de las mismas. Como puede observarse en la figura, la línea de tendencia mostrada en los resultados, nos indica que entre las capas 25 y 35 se muestra una tendencia de mayor precisión en la clasificación, siendo la mejor de ellas la capa número 29 con una precisión de un 92,32 %.

Si atendemos a los datos del *dataset MW2*, se obtienen mejores resultados que con el *dataset MW1*. Esto es debido a que las frutas van avanzando en su proceso de maduración, lo que hace que se encuentren más desarrolladas y por tanto las diferencias entre variedades empiecen a ser palpables. Como puede observarse, atendiendo nuevamente a la línea de tendencia mostrada, las últimas capas, entre las 129 y 137, ofrecen los mejores resultados de clasificación por variedad, teniendo en cuenta que todas las capas se obtienen una precisión mayor al 75 %. En este proceso de optimización del clasificador por variedad, se ha alcanzado el óptimo en la capa 130 con un 96,95 % de aciertos.

A medida que avanzamos en la semana de maduración,

*dataset MW3*, el clasificador mejora su precisión en todas sus capas respecto a los resultados obtenidos con los *datasets* anteriores. Casi todas las capas hiperespectrales del *dataset MW3* obtienen una precisión superior al 75 %. La línea de tendencia nos ayuda a confirmarlo. A diferencia de los *dataset* anteriores, en éste se encuentran varias capas con una precisión superior al 96,48 %.

Los resultados obtenidos con el último *dataset* utilizado, *MW4*, aportan buenos resultados globales de todas las capas en cuanto a precisión media para clasificar las variedades de ciruelo estudiadas. En esta última fase de maduración las diferencias entre las variedades son notorias a simple vista y esto permite que su clasificación sea más sencilla, es por ese motivo por el cual los resultados globales obtenidos son mejores. La línea de tendencia presente en la gráfica muestra que todas las capas obtienen buenos datos, estando la mayoría de las capas por encima del 80 %. El óptimo se encuentra en la capa 55 con un valor de precisión del 100,00 % en la clasificación por variedad.

Hasta aquí, podemos observar que a medida que la fruta madura, es más sencillo detectar su variedad, obteniendo un conjunto de capas hiperespectrales con mayor precisión. Estas características también pueden deberse a las diferentes fases de maduración que tienen las variedades que se han utilizado en este estudio. La variedad *Angeleno* es la que tiene mayor ciclo de maduración, de ahí que la fruta presenta menos cambios a lo largo del periodo estudiado, pero el resto si que presenta modificaciones, lo que permite a la red clasificar mejor las variedades.

En el estudio que se detalla a continuación, se han mezclado todas las fases de maduración de las diferentes variedades, para poder desestacionar la componente del tiempo de maduración. Con esto se pretende no facilitar a la red la detección gracias a grandes cambios en ciertas variedades y cambios pocos significativos en las variedades de ciclo largo. La Figura 4 muestra los resultados obtenidos de este nuevo estudio.

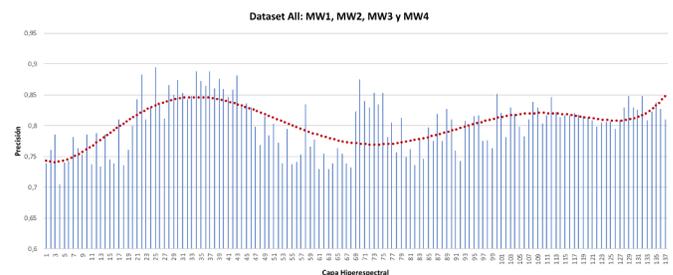


Figura 4. Resultado clasificación por variedad, *Dataset ALL*

El *dataset* utilizado donde la fecha de maduración del fruto no es relevante, arroja resultados del 70 % de precisión como mínimo. Si observamos la línea de tendencia presente en la Fig. 4 se aprecia que entre las capas 17 - 47 se obtienen muy buenos resultados, siendo la mejor capa la 25 con un 85 % de precisión. Este dato nos indica que es posible la clasificación de ciruelas por su variedad, gracias a la precisión obtenida del



85 %, siendo indiferente la fase de maduración en la que se encuentre el fruto.

La Tabla II muestra un resumen de las propuestas estudiadas con los diferentes *dataset* empleados. En esta tabla se resumen las capas que han obtenido mayores resultados, así como el intervalo de capas donde se aprecian diferencias con respecto al resto de capas.

Tabla II  
PROPOSICIÓN CAPAS PARA CLASIFICADOR

Semanas de maduración	<i>Dataset</i>	Capas	% acierto máximo
9–13 Mayo	MW1	29	92,32 %
23–27 Mayo	MW2	92, 130	96,95 %
13–17 Junio	MW3	15, 19, 75, 84, 101	96,48 %
4–9 of Julio	MW3	55	100,00 %
-	All_MW	25	89,45 %

Podemos observar, según los datos presentados, que a diferentes fases de maduración de los frutos, la información relevante para poder clasificar las variedades según las imágenes hiperespectrales, se encuentran en diferentes bandas del espectro.

Por otro lado, también podemos observar que los resultados son excelentes, si nos centramos en la capacidad de clasificación de las redes optimizadas, ya que, independientemente de las capas, es posible generar una buena clasificación de las variedades empleadas.

Si comparamos los datos obtenidos en el estudio que aquí se presenta, con los datos obtenidos en estudios similares, pero utilizando imágenes RGB, podemos observar ciertas diferencias. Anteriormente se ha abordado la problemática de la clasificación de ciruelas por su variedad mediante el uso de la misma CNN, *Alexnet* [15], pero con la diferencia que en este trabajo, las imágenes utilizadas eran imágenes RGB. Esta circunstancia nos permite comparar ambos estudios, resumiendo los datos en la Tabla III.

Tabla III  
RESUMEN DE RESULTADOS UTILIZANDO IMÁGENES RGB FRENTE A IMÁGENES HIPERESPECTRALES

<i>Dataset</i>	RGB	Hiperespectral - Número capa
MW1	0.8960 ± 0.010	0.9232 ± 0.060 - 29
MW2	0.9299 ± 0.015	0.9695 ± 0.040 - 130
MW3	0.9739 ± 0.008	0.9648 ± 0.030 - 19
MW4	0.9674 ± 0.005	1.0000 ± 0.010 - 55
All_MW	0.9071 ± 0.010	0.8945 ± 0.030 - 25

Como puede observarse, los resultados obtenidos al clasificar ciruelas usando imágenes hiperespectrales son superiores a los resultados obtenidos anteriormente, independientemente si lo que buscamos es un conjunto de capas que nos indiquen propiedades físico-químicas de las ciruelas que nos permitan realizar la clasificación, aunque si realizamos un test estadístico para comparar ambas técnicas nos ofrece resultados no significativos, como indica la Tabla IV-A.

Tabla IV  
TEST DE WILCOXON PARA COMAPRACIÓN DE TÉCNICAS

VS	$R^+$	$R^-$	P-value	P-value Asintótico
Híper	8.0	7.0	$\geq 0.2$	0.787406

Atendiendo a la capa que obtiene mejor resultado de clasificación, al utilizar imágenes hiperespectrales, y la misma red CNN *-Alexnet-*, los resultados son mejores que al utilizar imágenes RGB. Se podría afirmar que el estudio de la imagen hiperespectral, al contener propiedades físico-químicas del fruto, ofrece mejores resultados frente a una clasificación por imagen convencional, donde únicamente la forma, tamaño y color serían las componentes que intervienen en dicha clasificación.

#### IV-B. Resultados clasificación por estado de maduración

De igual forma que con los resultados presentados en la sección anterior, donde hemos obtenido buenos clasificadores que se centran en la variedad de la fruta analizada, en esta sección se presenta un nuevo estudio donde se optimizan clasificadores orientados a determinar la fecha de maduración de la misma.

En este caso, los *dataset* con los que se ha trabajado están agrupados por variedad y agrupados en 4 clases diferentes, cada una de las semanas de maduración cuando fueron recogidos los frutos. Se utilizan para este estudio nuevamente las imágenes hiperespectrales, donde se intenta encontrar un conjunto de bandas que nos permitan clasificar las frutas por su estado de maduración.

La Figura 5, muestra los resultados obtenidos.

Si observamos los resultados obtenidos por el clasificador de la variedad *Black Splendor* por semana de maduración, se observa que existe una gran diferencia entre las diferentes capas de las imágenes hiperespectrales. Como se puede ver en la Figura 5, la precisión obtenida se puede dividir en tres bloques que son claramente diferenciables. Un primer bloque, de la capa 1 - 65, con un buen índice de precisión, entorno al 96 %. El segundo bloque, rango comprendido entre la capa 66 - 113, donde la precisión decae hasta valores cercanos al 40 %. Un último bloque, 114 - 137, donde la precisión se sitúa de nuevo en el 96 %.

Por otro lado, los resultados obtenidos al clasificar imágenes hiperespectrales de la variedad *OwenT* muestran, que al igual que sucedía con los resultados obtenidos en la variedad *Black Splendor*, sus resultados pueden dividirse en tres bloques. En el primer bloque, que comprende de la capa 1 hasta la capa 17 tienen una precisión cercana al 98 %. El segundo bloque, capa 18 - 57, obtiene mala precisión, algunas de sus capas tienen una precisión del 25 %. De la capa 58 a la 137 la precisión crece situándose en un rango comprendido entre el 80 % y el 98 %.

Por último, a diferencia de lo que ocurre con las variedades *OwenT* y *Black Splendor* los resultados obtenidos al clasificar la variedad *Angeleno* por maduración son muy similares en todas sus capas. La precisión en ninguna de las capas es

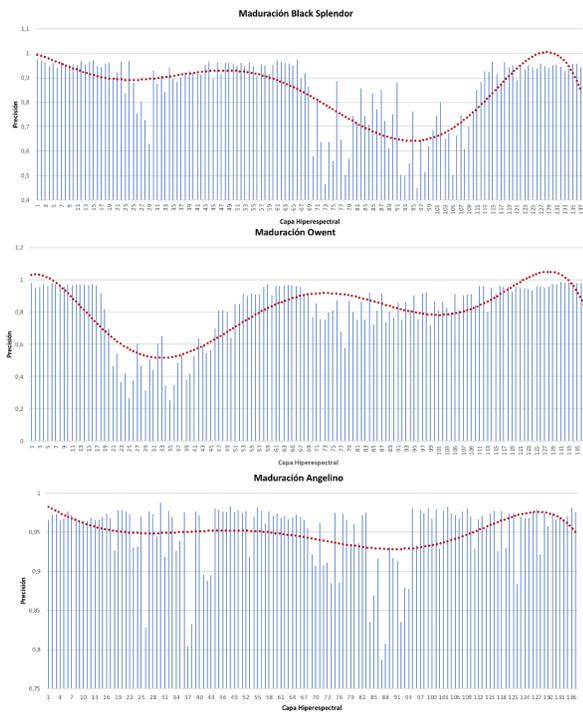


Figura 5. Clasificación por maduración: *Black Splendor*, *OwenT*, *Angelino*.

inferior al 80 %. La capa que ofrece mejor precisión es la capa 30 con un 98,78 %. Esto puede ser debido a que esta variedad es una variedad de ciclo muy largo, y las fechas en las que se ha recolectado los frutos, debido a su ciclo de maduración, no son lo suficientemente significativas en el tiempo.

A continuación, en la tabla V se muestra un resumen de las capas que obtienen los mejores resultados para cada una de las variedades.

Tabla V  
PROPOSICIÓN CAPAS PARA CLASIFICAR POR ESTADO DE MADURACIÓN

Varietal	Rango de capas	% máximo de acierto
<i>Angelino</i>	94 - 137	96 %
<i>Black Splendor</i>	1 - 65 / 114 - 137	98 %
<i>OwenT</i>	1 - 17 / 58 - 137	98,78 %

## V. CONCLUSIONES

Los resultados presentados en este trabajo muestran que es posible clasificar, con un alto rango de acierto, las variedades de ciruelo japonés seleccionadas para este estudio por medio de las imágenes hiperespectrales tomadas en un entorno de laboratorio. Los datos obtenidos demuestran que es posible clasificar la variedad de la ciruela atendiendo a su información hiperespectral y la semana de maduración en la que se encuentra, se han obtenido resultados del 92,32 %, 96,95 %, 96,48 % y 100,00 % respectivamente, para las cuatro fases de maduración empleadas en este estudio. Por otro lado, si la fase de maduración no se tiene en cuenta, se obtiene unos

resultados del 89,45 %. Estos datos superan un estudio previo donde se emplearon imágenes RGB, permitiendo obtener clasificadores más eficaces.

Estos resultados nos permiten afirmar que es posible clasificar la variedad de una ciruela gracias al estudio de su espectro. Además, los datos obtenidos y presentados, nos permiten vislumbrar ciertas zonas de interés en el espectro de las diferentes variedades, atendiendo a su fecha de maduración, donde, con un estudio más profundo, se podrán obtener propiedades físico-químicas de los frutos a través de su espectro.

## AGRADECIMIENTOS

Agradecemos el apoyo del Ministerio de Economía y Competitividad proyecto TIN2017-85727-C4-{2,4}-P, Junta de Extremadura, Consejería de Comercio y Economía, proyecto IB16035 a través del Fondo Europeo de Desarrollo Regional, “Una manera de hacer Europa”.

## REFERENCIAS

- [1] Wang, H., Peng, J., Xie, C., Bao, Y., He, Y. “Fruit quality evaluation using spectroscopy technology: a review,” *Sensor* 15(5), 11889-11927, 2015.
- [2] Sergio Cubero, Nuria Aleixos, Enrique Moltó, Juan Gómez-Sanchis, and Jose Blasco. “Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables,” *Food and Bioprocess Technology*, 4(4):487-504, 2011.
- [3] M.T. Riquelme, P. Barreiro, M. Ruiz-Altisent, and C. Valero. “Olive classification according to external damage using image analysis,” *Journal of Food Engineering*, 87(3):371-379, 2008.
- [4] P.B. Pathare, U.L. Opara, and F. A. J. Al-Said. “Colour measurement and analysis in fresh and processed foods: A review,” *Food and Bioprocess Technology*, 6(1):36-60, 2013.
- [5] Pal, M. “Random forest classifier for remote sensing classification,” *International Journal of Remote Sensing*, 26(1), 217-222. 2005.
- [6] Danfeng Wang, Xichang Wang, Taiang Liu and Yuan Liu, “Prediction of total viable counts on chilled pork using an electronic nose combined with support vector machine,” *Meat Science*, Volume:90, pag:373 - 377, 2012.
- [7] Krizhevsky, A., Sutskever, I., Hinton “Imagenet classification with deep convolutional neural networks. In: *Bartlett, P., Pereira, F., Burges, C., Bottou, L., Weinberger, K. (eds.)* Advances in Neural Information Processing Systems 25, pp. 1106-1114, 2012
- [8] C. Yang, W.S. Lee, and P. Gader. “Hyperspectral band selection for detecting different blueberry fruit maturity stages,” *Computers and Electronics in Agriculture*, 109:23-31, 2014.
- [9] Lu, R., Ariana, D. P. “Detection of fruit fly infestation in pickling cucumbers using a hyperspectral reflectance/transmittance imaging system,” *Postharvest Biology and Technology*, 81, 44-50, 2013.
- [10] Haff, R. P., Saranwong, S., Thanapase, W., Janhira, A., Kasemsumran, S., Kawano, S. “Automatic image analysis and spot classification for detection of fruit fly infestation in hyperspectral images of mangoes,” *Postharvest Biol. Technol.* 86, 23-28, 2013
- [11] Dubey, S. R., Jalal, A. S. “Adapted approach for fruit disease identification using images,” arXiv preprint arXiv:1405.4930, 2014
- [12] Hailong Wang, Jiyu Peng, Chuanqi Xie, Yidan Bao y Yong He “fruit quality evaluation using spectroscopy”, *Sensor*, 21 mayo 2015
- [13] S. Edward Law. “Scatter of near-infrared radiation by cherries as a means of pit detection,” *Journal of Food Science*, 38(1):102 - 107, 1973.
- [14] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. “Deep learning” *Nature* 521, no. 7553 436-444, 2015
- [15] Rodríguez, Francisco J., García, Antonio, Pardo, Pedro J., Chávez, Francisco, Luque-Baena, Rafael M., “Study and classification of plum varieties using image analysis and deep learning techniques” *Progress in Artificial Intelligence*, 7(2), 119-127, 2018
- [16] Krizhevsky, Alex and Sutskever, Ilya and Hinton, Geoffrey E., “Image-Net Classification with Deep Convolutional Neural Networks” *NIPS'12*, 1097-1105, 2012



# Preprocesamiento guiado por luminosidad para la detección automática de armas blancas en video vigilancia con Deep Learning

Alberto Castillo · Siham Tabik · Francisco Pérez · Roberto Olmos · and Francisco Herrera

\*Andalusian Research Institute in Data Science and Computational Intelligence, University of Granada, 18071 Granada, Spain.

Email: albertocl@decsai.ugr.es, siham@ugr.es, fperezhernandez@ugr.es, herrera@decsai.ugr.es

**Resumen**—La detección automática de armas blancas empuñadas por una o varias personas presentes en los vídeos de vigilancia pueden ayudar a reducir los delitos. Sin embargo, la detección de este tipo de objetos en vídeos se enfrenta a varios problemas, tales como la producida por la variabilidad de la luz ambiental junto con la reflectancia de la superficie de las armas blancas. El objetivo de este trabajo es doble: i) Elaborar un modelo de detección automático de armas blancas para la videovigilancia mediante redes neuronales convolucionales (CNN) y ii) reforzar su robustez frente a diferentes condiciones lumínicas proponiendo una metodología de preprocesamiento guiado por luminosidad llamada DaCoLT (*Darkening and Contrast at Learning and Test stages*) para abordar condiciones de luminosidad perjudiciales.

## I. INTRODUCCIÓN

Según la Organización Mundial de la Salud <sup>1</sup>, cada año mueren más de 15,000 personas en crímenes violentos. Alrededor del 40% por ciento de estos homicidios se cometen con navajas y armas blancas punzantes. En la videovigilancia, los agentes de seguridad tienen que detectar visualmente la presencia de armas en escenas monitorizadas y tomar decisiones en muy poco tiempo. Una de las soluciones más efectivas ante este problema es equipar las cámaras de vigilancia con un sistema automático y preciso de detección de armas blancas.

La mayoría de los estudios previos abordaron la detección de armas en rayos X, imágenes milimétricas o RGB utilizando métodos clásicos de aprendizaje automático [5], [6], [15], [16], [17]. Actualmente, los modelos de detección de objetos más precisos son basados en técnicas de Deep Learning, particularmente modelos basados en CNNs. El primer trabajo para abordar la detección de armas en vídeos utilizando CNNs fue [11]. Este trabajo se centró en las pistolas y fue evaluado en vídeos de películas de los noventa.

Por lo que sabemos, el presente estudio es el primero en desarrollar un sistema de detección de armas blancas usando Deep Learning y abordando el problema de la luminosidad aplicado en vídeos de vigilancia grabados en escenarios interiores. La detección de armas blancas en los vídeos de vigilancia en escenas de interior afronta varios desafíos:

- Las armas blancas pueden manejarse de diferentes formas y una gran parte del arma puede ser ocluida. Además,

las armas blancas comunes, como los cuchillos, son pequeñas y la distancia entre el cuchillo y la cámara puede ser grande, lo que hace que la detección sea más difícil.

- El proceso de diseño de un nuevo conjunto de datos para entrenar con éxito el modelo de detección es manual y lleva mucho tiempo.
- La detección es sensible a la luz ambiental ya que, en general, las armas blancas, como los cuchillos, tienen superficies reflectantes.

Nos enfocamos en detectar con precisión los tipos más usados de armas blancas en delitos. Construimos un nuevo conjunto de datos que permite que el modelo aprenda con éxito las características distintivas de las armas blancas. A continuación, desarrollamos un modelo de detección de armas blancas apropiado para escenarios interiores y bajo diferentes condiciones de luz. Estudiamos las condiciones de luminosidad que afectan al rendimiento de la detección y proponemos una nueva metodología de preprocesamiento para solucionar los problemas de luminosidad.

Las principales contribuciones de este trabajo pueden resumirse como sigue:

- Construir una nueva base de datos etiquetada para detección de armas blancas, guiado por el proceso de clasificación.
- Analizar la mejor combinación de clasificadores basados en CNN y técnicas de selección de región para la detección automática de armas blancas en vídeos de vigilancia en escenarios interiores.
- Proponer una nueva metodología de preprocesamiento guiada por luminosidad, llamada Darkening and Contrast at Learning and Test time (DaCoLT), para superar las condiciones de luminosidad perjudiciales.

Nuestro estudio experimental muestra que el modelo de detección más preciso entrenado en nuestra nueva base de datos es R-FCN basado en ResNet-101, proporciona una medida F1 de 93%. El F1 obtenido por el modelo en diferentes condiciones de luminosidad empeoraron hasta en un 15% y usando nuestra metodología DaCoLT lo redujimos al 3%.

Este documento está organizado de la siguiente manera. La sección II da un breve análisis de los estudios de investigación

<sup>1</sup>[http://www.euro.who.int/\\_\\_data/assets/pdf\\_file/0012/121314/E94277.pdf](http://www.euro.who.int/__data/assets/pdf_file/0012/121314/E94277.pdf)

más relacionados. La sección III describe el procedimiento para construir nuestra nueva base de datos de calidad para detección. La sección IV selecciona el modelo más adecuada para su uso como sistema de detección automática. Sección V analiza el rendimiento de detección en diferentes condiciones de luminosidad y propone la metodología DaCoLT. Finalmente, las conclusiones se resumen en la sección VI.

## II. TRABAJOS RELACIONADOS

El problema de detectar un cuchillo empuñado por una persona en videovigilancia está estrechamente relacionado con (i) la detección de objetos pequeños en imágenes y ii) detección general de objetos mediante modelos de aprendizaje profundo.

El área tradicional de detección de armas en imágenes ha utilizado a menudo métodos clásicos supervisados de aprendizaje automático que requieren un alto nivel de supervisión humana, por ejemplo, FAST [2], SIFT [5], AAM [6], Harris [15]. Los medios utilizados son principalmente rayos X o imágenes milimétricas [16], [17] para armas ocultas y RGB para armas visibles [2], [6], [7]. En general, estos métodos proporcionan buenas precisiones pero sufren de varias limitaciones, son invasivas, necesitan costosas sistemas de detección de metales [5] como los sistemas utilizados en el acceso al aeropuerto, no puede detectar múltiples armas [9], [15] y son lentos para usar en sistemas de detección en tiempo real [2].

Los modelos de detección de objetos de última generación se basan en Convolutional Neural Networks y muestran resultados prometedores en los dos desafíos de detección más prestigiosos. El modelo de detección más preciso de ILSVRC 2017 (Large Scale Visual Recognition Challenge) [4] alcanzó una precisión media de alrededor del 73%<sup>2</sup> en un benchmark de 527892 imágenes dispuestas en 200 clases de objetos, con un promedio de 2500 imágenes por clase. El modelo de detección más preciso en el benchmark de detección de 80 objetos comunes Common Objects in Context (COCO) [10] también alcanzó una precisión media de alrededor del 73%. Los rendimientos más altos en COCO tiene una precisión del 60% y un recall del 80% pero fueron obtenidos en objetos grandes, y de menor rendimiento con una precisión del 30% y un recall del 50% en objetos pequeños<sup>3</sup>.

Por lo que sabemos, el primer sistema automático de detección de armas de fuego basado en Deep Learning fue [11]. Este trabajo demostró ser preciso en las películas (descargadas de YouTube) con mejor calidad, es decir, mejor resolución, contraste y luminosidad que los vídeos comunes de vigilancia. Los mejores resultados reportados en este trabajo fueron obtenidos por el modelo de detección Faster R-CNN [12] basado en VGGNet [14] y con una velocidad de cinco fotogramas por segundo (fps), que es una tasa baja para un sistema de tiempo real.

<sup>2</sup><http://image-net.org/challenges/LSVRC/2017/>

<sup>3</sup><http://cocodataset.org/#detections-leaderboard>

## III. PROCEDIMIENTO DE CONSTRUCCIÓN DE LA BASE DE DATOS PARA LA DETECCIÓN DE ARMAS BLANCAS

Nuestro objetivo es construir una base de datos que permita al modelo de detección distinguir con precisión entre cuchillos y todos los objetos que puedan confundirse con cuchillos. Con este fin, primero comenzamos con un conjunto de datos de clasificación inicial, Database-1, y lo ampliamos progresivamente con nuevas clases de objetos para mejorar el número de true positives (#TP), false positives (#FP), true negatives (#TN) y false negatives (#FN) producidos por un modelo de clasificación simple (VGG-16). Este análisis nos permite entender qué objetos son críticos en el proceso de aprendizaje y considerarlos como objetos en el fondo de las imágenes de la base de datos a la hora de construir la base de datos final para detección.

Extendimos la base de datos en tres pasos:

- Database-1 incluye 2 clases, la clase de cuchillos contiene imágenes de cuchillos de diversos tamaños y la otra clase con diversos fondos.
- Database-2 contiene 28 clases e incluye nuevas clases de objetos que a menudo están presentes como fondo en la clase cuchillos de Database-1.
- Database-3 incluye clases de objetos que pueden manejarse de forma similar a un cuchillo, por ejemplo, bolígrafo, o teléfono móvil, ver cuatro ejemplos en la figura 1.

Las imágenes utilizadas para construir la Database-1, -2 y -3 fueron descargadas de diversos sitios web. Las características de las tres bases de datos auxiliares, Database-1, 2 y 3, se muestran en la Tabla I

Para evaluar el rendimiento de la clasificación y detección sobre las bases de datos propuestas, hemos construido dos conjuntos de pruebas, Test-clas y Test-det.

- Test-clas se utiliza para evaluar el modelo de clasificación, consta de 512 imágenes, 260 imágenes contienen la clase cuchillo y 252 imágenes contienen otras clases de objetos.
- El Test-det se utiliza para evaluar los modelos de detección, contiene 388 imágenes, 378 contienen al menos un cuchillo. Test-det incluye fotogramas tomados por una cámara IP de videovigilancia (Hikvision DS-2CD2420F-IW 1080p para vídeo, ratio de frames 30 fps, campo de visión 95° y compresión MJPEG).

Figura 1: Imágenes de ejemplo de cuatro clases de objetos de la base de datos 3, (a) clase cuchillo, (b) clase bolígrafo, (c) clase teléfono móvil y (d) clase cigarrillos.



Usamos Keras API 2.0.4 [3] para los experimentos. Medimos el rendimiento, precisión, recall, y F1, obtenidos por el



Tabla I: Características de las bases de datos.

Database-	clases	total img	img arma	otras img	enfoque
1	2	1654	598	1056	clasificación
2	28	5538	598	4940	clasificación
3	100	10039	618	9421	clasificación
4	1	1250	1250	-	detección
Test-clas	-	512	260	252	clasificación
Test-det	-	388	378	10	detección

Tabla II: Resultados del modelo de clasificación para la clase cuchillo.

Database-	#TP	#FN	#TN	#FP	Precisión	Recall	F1 score
1	181	79	174	78	69,88 %	69,62 %	69,75 %
2	209	51	228	24	89,70 %	80,38 %	84,78 %
3	213	47	228	24	<b>89,87 %</b>	<b>81,92 %</b>	<b>85,71 %</b>

modelo de clasificación cuando se entrena en Database-1, -2 y -3 se muestra en la Tabla II. El rendimiento de la clase de cuchillo ha aumentado al ampliar el conjunto de datos con más clases de objetos. El mejor rendimiento se obtiene cuando el modelo es entrenado en Database-3, pero no puede ser usada directamente para entrenar el modelo de detección ya que el detector requiere una estrategia de anotación diferente.

Como paso final, construimos el conjunto de entrenamiento, Database-4, teniendo en cuenta todas las clases de objetos, de Database-1,-2 y -3, que mejoran el aprendizaje porque se manejan de la misma manera que un cuchillo o tienen características similares a las de un cuchillo. A diferencia de la clasificación de imágenes, el proceso de anotación para la detección requiere indicar la clase de objeto utilizando un cuadro delimitador. Consideramos dos clases, el cuchillo como la clase verdadera y el resto de objetos como fondo. Incluimos imágenes de i) armas blancas de diversos tipos, formas, colores, tamaños y hechos de diferentes materiales ii) cuchillos ubicados cerca y lejos de la cámara, iii) cuchillos ocultos parcialmente por la mano, iv) objetos que pueden ser empuñados de la misma manera que los cuchillos y v) imágenes capturadas en escenarios de interior y exterior, conjunto de datos de 1250 imágenes. Figura 2 muestra ejemplos de Database-4.

Las imágenes utilizadas para construir esta base de datos fueron descargadas de Internet, algunos fotogramas fueron extraídos de vídeos de Youtube y vídeos de vigilancia. En el resto del trabajo usaremos Database-4 para entrenar el modelo de detección.

Figura 2: Imágenes de ejemplo de Database-4. Estas imágenes muestran un contexto más rico.



#### IV. ANÁLISIS DEL ENFOQUE DE DEEP LEARNING PARA LA DETECCIÓN DE ARMAS BLANCAS

En esta sección, analizamos el rendimiento de varias combinaciones de los modelos de clasificación más avanzados y algoritmos de selección de regiones con el objetivo de encontrar el mejor modelo de detección para la videovigilancia. En particular, analizamos estas combinaciones:

- SSD basado en Inception-v2
- R-FCN basado en ResNet101
- Faster R-CNN basado en: Inception-ResNetV2, ResNet50, ResNet101 y Inception-V2

Todos los modelos de clasificación y detección se construyeron utilizando TensorFlow [1]. Para evaluar la detección usamos Tensorflow Object Detection API [8]. Todos los experimentos fueron llevados a cabo en una GPU NVIDIA Titan Xp.

Todos los modelos de detección fueron inicializados usando los pesos pre-entrenados en el conjunto de datos COCO integrado por más de 200.000 imágenes etiquetadas. Utilizamos fine-tuning mediante el entrenamiento de las dos últimas capas completamente conectadas de la red. El proceso de entrenamiento dura de tres a cuatro horas.

Tabla III: Analisis comparativo de los modelos de detección del estado del arte.

Detector	modelo base CNN	#TP	#FP	Precisión	Recall	F1	fps
Faster R-CNN	Inception-ResNetV2	345	0	100 %	91,27 %	<b>95,44 %</b>	1,3
Faster R-CNN	ResNet101	332	8	97,65 %	89,73 %	93,52 %	4,8
Faster R-CNN	Inception-V2	329	3	99,1 %	87,04 %	92,64 %	12,8
Faster R-CNN	ResNet50	326	2	99,39 %	86,24 %	92,35 %	4,4
R-FCN	ResNet101	335	0	100 %	88,62 %	93,97 %	10
SSD	InceptionV2	245	0	100 %	64,81 %	78,65 %	20,4

El rendimiento de los modelos de detección se mide en términos de true positives, false positives, precision, recall, F1 y tasa de tiempo de inferencia (frames per second). El entrenamiento y el test se llevaron a cabo en Database-4 y test-det respectivamente. En general, los modelos de detección logran un alto rendimiento como se puede ver en la Tabla III. Esto se explica por el hecho de que el aprendizaje transferido de COCO ha sido muy beneficioso para el proceso de aprendizaje, ya que COCO incluye la clase cuchillos compuesta por unas 8.500 imágenes. Al centrarnos en la videovigilancia, la detección debe ser precisa y rápida al mismo tiempo. Por lo tanto, seleccionamos R-FCN\_ResNet101 para construir nuestro detector de armas blancas. Utilizando 100 regiones de interés R-FCN\_ResNet101 logra una buena precisión 100 %, recall 88,62 % y F1 93,97 %, lo que está cerca del mejor modelo y proporciona una tasa razonable de inferencia.

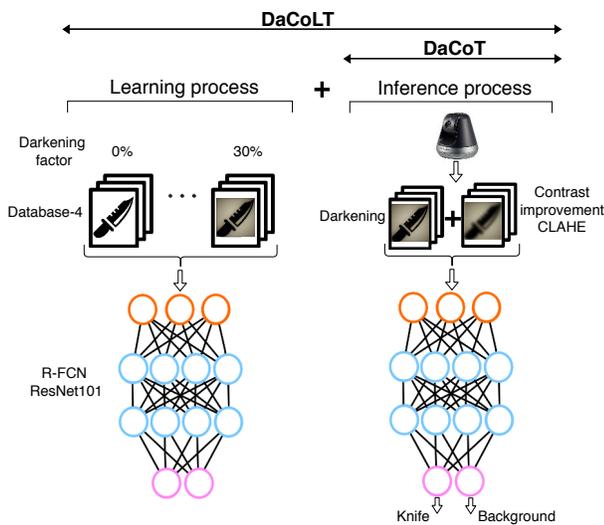
Todo el proceso de detección utiliza R-FCN\_ResNet101 en una resolución por fotograma de Full HD, 1920 × 1080-píxeles, que es dos veces más rápido que el detector de pistola propuesto en [11]. Esto permite que el detector de armas blancas pueda ser usado en tiempo real para la videovigilancia.

## V. PREPROCESAMIENTO GUIADO POR LUMINOSIDAD: METODOLOGÍA DACOLT

Para resolver los problemas de luminosidad, proponemos dos alternativas:

- DaCoT: durante el proceso de prueba, los fotogramas con luminosidad alta son oscurecidos por un factor específico, luego su contraste es mejorado usando el algoritmo CLAHE.
- DaCoLT: durante el proceso de aprendizaje, el modelo de detección se entrena utilizando una técnica específica de *data augmentation* para oscurecimiento. Luego, DaCoT se aplica durante el tiempo de prueba. La diferencia entre estos dos procedimientos se ilustra en la figura 3.

Figura 3: Una ilustración de nuestro procedimiento, DaCoT se aplicó en el tiempo de test y DaCoLT se aplicó tanto en el tiempo de aprendizaje como en el tiempo de test.



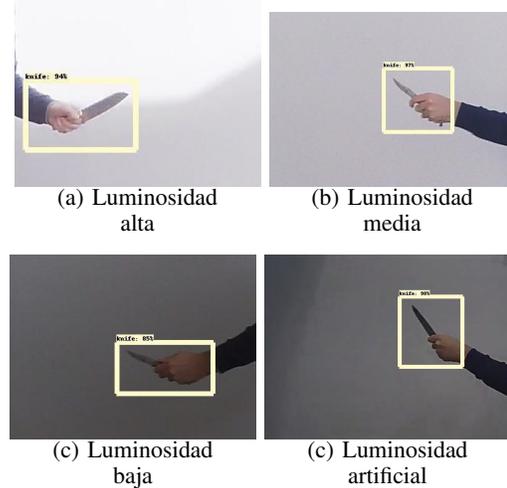
En particular, primero determinamos el rango de luminosidad que afecta la calidad de la detección (sección V-A), a continuación, se analiza y mejora la detección simulando las condiciones ideales de luminosidad en test (sección V-B) y tanto en tiempo de aprendizaje como test (sección V-C).

### V-A. Análisis del impacto de la luminosidad en el rendimiento de detección

A continuación, analizamos el impacto de las condiciones de luminosidad en el rendimiento del modelo de detección R-FCN\_ResNet101. Usamos doce vídeos de prueba grabados con una cámara de seguridad IP, Samsung SNH-V6410PN de resolución 1080p, frame rate 30fps y amplitud de vista 96.1°. Los vídeos de prueba se dividen en cuatro grupos de diferentes condiciones de luminosidad, luminosidad alta, luminosidad media, luminosidad baja y luminosidad artificial. Para una comparación justa, todos los vídeos muestran a la misma persona repitiendo las mismas acciones al mismo tiempo y distancia de la cámara. Todos los vídeos fueron grabados usando la misma cámara en la misma escena interior. Los vídeos de prueba incluyen tres cuchillos comunes con diferentes tamaños, pequeño, mediano y grande. Pequeño,

mediano y grande se refieren a la proporción de la parte no ocluida del arma. Ver ejemplos en la figura 4. Los vídeos de test se pueden encontrar a través de este repositorio en github <sup>4</sup>.

Figura 4: Resultados de detección en cuatro condiciones de luminosidad diferentes.



Consideramos que un cuchillo es un ground truth cuando es reconocible por el ojo humano. Los resultados en términos de número total de Ground Truth positivos #GT\_P, #TP, #FP, precisión, recall, y F1 en cada vídeo de prueba se muestran en la Tabla IV. Consideramos una detección como TP si el solapamiento entre el área del cuchillo manipulada en el fotograma y la caja delimitadora predicha es mayor que 70%.

Tabla IV: Rendimiento de detección obtenido en vídeos grabados en diferentes condiciones de luminosidad.

Luminosidad	Tamaño arma	#frames	#GT_P	#TP	#FP	Precisión	Recall	F1
Alta	Grande	121	112	78	0	100%	69,64%	82,10%
	Mediano	107	90	44	0	100%	48,89%	65,67%
	Pequeño	137	103	53	0	100%	51,46%	67,95%
<i>Promedio</i>						100%	56,66%	71,91%
Media	Grande	109	98	85	0	100%	86,73%	92,89%
	Mediano	116	98	73	0	100%	74,49%	85,38%
	Pequeño	138	110	64	0	100%	58,18%	73,56%
<i>Promedio</i>						100%	73,13%	83,94%
Baja	Grande	126	114	104	1	99,05%	92,04%	95,41%
	Mediano	114	100	70	0	100%	70%	82,35%
	Pequeño	138	101	74	0	100%	73,27%	84,57%
<i>Promedio</i>						99,68%	78,44%	87,44%
Artificial	Grande	119	110	95	0	100%	86,36%	92,68%
	Mediano	113	99	75	3	96,15%	78,13%	86,21%
	Pequeño	96	90	65	4	94,20%	75,58%	83,87%
<i>Promedio</i>						96,78%	<b>80,02%</b>	<b>87,59%</b>

Como se puede observar en la Tabla IV, el rendimiento del modelo de detección es inestable en un escenario de cambio de luminosidad. El peor rendimiento se obtiene en condiciones de alta luminosidad, y el mejor rendimiento con luminosidad artificial. De las condiciones de luminosidad más bajas a las

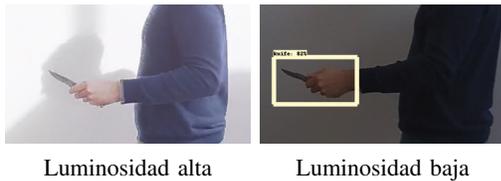
<sup>4</sup><https://github.com/alcasla/Automatic-Cold-Steel-Detection-Alarm>



más altas, el recall promedio disminuyó de 80,02% a 56,66%, y el F1 promedio de 87,59% a 71,91%.

La Figura 5 muestra un ejemplo de los resultados de detección de escenas muy similares, es decir, la misma pose y contexto, diferentes niveles de luminosidad y contraste, pero diferentes resultados de detección.

Figura 5: Un ejemplo del resultado de la detección en dos situaciones similares con diferentes condiciones de luminosidad.



### V-B. Darkening and Contrast at Test stage (DaCoT)

Para resolver la inestabilidad del modelo de detección en condiciones de luminosidad variable, primero analizamos el procedimiento llamado DaCoT, Oscurecimiento y Contraste en tiempo de test, el cual simula la condición de luminosidad que produce el mejor desempeño, luminosidad baja y alto contraste. Procedemos de la siguiente manera:

- Primero comprobamos el nivel de luminosidad de cada fotograma. Si el nivel de luminosidad es de medio a alto, oscureceremos el fotograma multiplicando los valores de los píxeles por el factor de oscurecimiento correspondiente. Este factor se calcula en base a la diferencia entre el nivel de luminosidad ideal y el nivel de luminosidad actual de la imagen.
- A continuación, aumentamos el contraste del fotograma obtenido mediante el algoritmo *Contrast-Limited Adaptive Histogram Equalization* (CLAHE) [13].
- A continuación, el fotograma se introduce al modelo de detección para inferencia.

La evaluación del enfoque propuesto en condiciones de luminosidad alta al considerar diferentes factores de oscurecimiento se proporciona en la Tabla V. El rendimiento del modelo de detección ha mejorado cuando se utiliza un factor de oscurecimiento del 30%. En promedio, con un factor de oscurecimiento de 30% el recall y F1 han mejorado en 6,53% y 5,07% respectivamente en comparación con la condición original de luminosidad alta.

El preprocesamiento propuesto, oscurecimiento más CLAHE, tarda alrededor de  $29 \pm 3$  ms por fotograma en la CPU, lo que no ralentiza el proceso general de detección, ya que esta tarea de preprocesamiento se realiza en paralelo con la tarea de detección en la GPU. Es decir, la hebra de preprocesamiento se ejecuta en la CPU y la de detección se ejecuta en la GPU.

### V-C. Darkening and Contrast at Learning and Test stages (DaCoLT)

Del análisis anterior, encontramos que el DaCoT mejora el rendimiento del modelo de detección bajo condiciones

Tabla V: Los resultados de los fotogramas de vídeo grabados originalmente en condiciones de luminosidad alta (es decir, en el peor de los casos) al aplicar DaCoT.

Factor oscurecimiento	Tamaño arma	#frames	#GT_P	#TP	#FP	Precisión	Recall	F1
original luminosidad alta	Grande	121	112	78	0	100 %	69,64 %	82,11 %
	Mediano	107	90	44	0	100 %	48,89 %	65,67 %
	Pequeño	137	103	53	0	100 %	51,46 %	67,95 %
Promedio						100 %	56,66 %	71,91 %
10 %	Grande	121	112	81	0	100 %	72,32 %	83,94 %
	Mediano	107	90	52	0	100 %	57,78 %	73,24 %
	Pequeño	137	103	57	1	98,28 %	55,34 %	71,25 %
Promedio						99,43 %	61,81 %	76,14 %
20 %	Grande	121	112	83	0	100 %	74,11 %	85,13 %
	Mediano	107	90	55	0	100 %	61,11 %	75,86 %
	Pequeño	137	103	53	0	100 %	51,46 %	67,95 %
Promedio						100 %	62,23 %	76,31 %
30 %	Grande	121	112	85	0	100 %	75,89 %	86,29 %
	Mediano	107	90	56	0	100 %	62,22 %	76,71 %
	Pequeño	137	103	53	0	100 %	51,46 %	67,95 %
Promedio						100 %	<b>63,19 %</b>	<b>76,98 %</b>
40 %	Grande	121	112	80	0	100 %	71,43 %	83,33 %
	Mediano	107	90	52	0	100 %	57,78 %	62,60 %
	Pequeño	137	103	51	0	100 %	49,51 %	66,23 %
Promedio						100 %	59,57 %	70,72 %
50 %	Grande	121	112	78	0	100 %	69,64 %	82,11 %
	Mediano	107	90	41	0	100 %	45,56 %	65,67 %
	Pequeño	137	103	50	0	100 %	48,54 %	65,36 %
Promedio						100 %	54,58 %	71,04 %

de luminosidad alta. En esta sección, analizamos el uso de DaCoLT, que es una extensión del DaCoT, mediante la aplicación de diferentes niveles de oscurecimiento no sólo en la etapa de prueba sino también durante la etapa de aprendizaje del modelo de detección. El método de aumento de datos de oscurecimiento consiste en oscurecer imágenes de entrenamiento individuales seleccionando aleatoriamente un factor de oscurecimiento en el rango [0% 30%].

Tabla VI: Los resultados al aplicar DaCoT y DaCoLT en vídeos grabados originalmente bajo condiciones de luminosidad alta usando diferentes tamaños de cuchillos, grande, mediano y pequeño.

	Tamaño arma	#frames	#GT_P	#TP	#FP	Precisión	Recall	F1
original luminosidad alta	Grande	121	112	78	0	100 %	69,64 %	82,11 %
	Mediano	107	90	44	0	100 %	48,89 %	65,67 %
	Pequeño	137	103	53	0	100 %	51,46 %	67,95 %
Promedio						100 %	56,66 %	71,91 %
guiado lumino. DaCoT (Test)	Grande	121	112	85	0	100 %	75,89 %	86,29 %
	Mediano	107	90	56	0	100 %	62,22 %	76,71 %
	Pequeño	137	103	53	0	100 %	51,46 %	67,95 %
Promedio						100 %	63,19 %	76,98 %
guiado lumino. DaCoLT (Train+Test)	Grande	121	112	84	0	100 %	75 %	85,71 %
	Mediano	107	90	64	0	100 %	71,11 %	83,12 %
	Pequeño	137	103	74	0	100 %	71,84 %	83,61 %
Promedio						100 %	<b>72,65 %</b>	<b>84,15 %</b>

La Tabla VI muestra el impacto al aplicar DaCoLT en el rendimiento de detección para las peores condiciones de luminosidad. La primera parte muestra los resultados del modelo de

detección en vídeos filmados originalmente en condiciones de luminosidad alta y utilizando diferentes tamaños de cuchillos, grandes, medianas y pequeñas. La segunda parte muestra el efecto de aplicar el enfoque de preprocesamiento propuesto en la etapa de inferencia, DaCoT. La tercera parte muestra el efecto de la metodología DaCoLT propuesta durante las etapas de inferencia y aprendizaje. De esta tabla podemos ver que el paso de data augmentation incluido en DACOLT mejora el aprendizaje del modelo de detección bajo condiciones de luminosidad alta. El recall y F1 promedio han mejorado respectivamente en 9,46% y 7,17% en comparación con el rendimiento considerando sólo el preprocesamiento en el momento de la inferencia, DaCoT.

Aplicando el preprocesamiento de luminosidad durante los pasos de inferencia y aprendizaje en los vídeos filmados bajo condiciones de luminosidad alta, se mejora el recall en 15,99% y el F1 en 12,24% en comparación con las condiciones de luminosidad alta originales.

Como estudio final, mostramos en la Tabla VII los resultados al aplicar la metodología de preprocesamiento DaCoLT en vídeos filmados bajo diferentes condiciones de luminosidad.

Tabla VII: El efecto de aplicar la metodología DaCoLT en vídeos filmados originalmente bajo diferentes condiciones de luminosidad.

Luminosidad	Tamaño	#Frames	#GT	#P	#TP	#FP	Precisión	Recall	F1	orig. F1
Alta	Grande	121	112	84	0		100%	75,00%	85,71%	82,10%
	Mediano	107	90	64	0		100%	71,11%	83,12%	65,67%
	Pequeño	137	103	74	0		100%	71,84%	83,61%	67,95%
	<i>Promedio</i>						100%	72,65%	84,15%	71,91%
Media	Grande	109	98	84	0		100%	85,71%	92,31%	92,89%
	Mediano	116	98	78	0		100%	79,59%	88,64%	85,38%
	Pequeño	138	110	75	0		100%	68,18%	81,08%	73,56%
	<i>Promedio</i>						100%	77,83%	87,34%	83,94%
Baja	Grande	126	114	103	0		100%	90,35%	94,93%	95,41%
	Mediano	114	100	74	0		100%	74,00%	85,06%	82,35%
	Pequeño	138	101	72	0		100%	71,29%	83,24%	84,57%
	<i>Promedio</i>						100%	<b>78,55%</b>	<b>87,74%</b>	87,44%
Artificial	Grande	119	110	95	0		100%	86,36%	92,68%	92,68%
	Mediano	113	99	73	1		98,65%	74,49%	84,88%	86,21%
	Pequeño	96	90	63	1		98,44%	70,79%	82,36%	83,87%
	<i>Promedio</i>						99,03%	77,21%	86,64%	87,59%

Como se observa, DaCoLT mejora la detección especialmente en las peores condiciones (luminosidad más alta). En otras palabras, DaCoLT permite alcanzar precisiones similares en los vídeos independientemente de su nivel de luminosidad.

## VI. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo presenta un modelo de detección automática de armas blancas para videovigilancia basado en una nueva metodología de preprocesamiento guiado por luminosidad, denominado DaCoLT, que mejora la calidad de la detección. El modelo de detección obtenido muestra un alto potencial incluso en vídeos de baja calidad.

Nuestro sistema de detección de armas blancas puede ser utilizado en varias aplicaciones, por ejemplo, i) detección en tiempo real de armas blancas en videovigilancia y ii) control parental de vídeos o imágenes con contenido violento.

Como trabajo futuro, abordaremos la detección de armas en escenarios al aire libre, donde pueden estar presentes objetos en movimiento y las condiciones climáticas adversas pueden aumentar la dificultad de la detección.

## AGRADECIMIENTOS

Este trabajo contó con el apoyo del Ministerio de Ciencia y Tecnología de España bajo el proyecto TIN2017-89517-P. Siham Tabik contó con el apoyo del Programa Ramón y Cajal (RYC-2015-18136). La GPU Titan X Pascal utilizada para esta investigación fue donado por NVIDIA Corporation.

## REFERENCIAS

- [1] Martín Abadi, Paul Barham, Jianmin Chen, Zhifeng Chen, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Geoffrey Irving, Michael Isard, et al. Tensorflow: A system for large-scale machine learning. *Operating Systems Design and Implementation*, 16:265–283, 2016.
- [2] Himanshu Buckchash and Balasubramanian Raman. A robust object detector: Application to detection of visual knives. *IEEE Multimedia and Expo Workshops*, pages 633–638, July 2017.
- [3] François Chollet. Keras: Theano-based deep learning library. *Code: github.com/fchollet. Documentation: http://keras.io*, 2015.
- [4] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255, June 2009.
- [5] Greg Flittton, Toby P Breckon, and Najla Megherbi. A comparison of 3d interest point descriptors with application to airport baggage object detection in complex ct imagery. *Pattern Recognition*, 46(9):2420–2436, 2013.
- [6] Andrzej Glowacz, Marcin Kmiec, and Andrzej Dziech. Visual detection of knives in security applications using active appearance models. *Multimedia Tools and Applications*, 74(12):4253–4267, Jun 2015.
- [7] Michał Grega, Andrzej Matiołański, Piotr Guzik, and Mikołaj Leszczuk. Automated detection of firearms and knives in a cctv image. *Sensors*, dx.doi.org/10.3390/s16010047, 16(1), 2016.
- [8] Jonathan Huang, Vivek Rathod, Chen Sun, Menglong Zhu, Anoop Korattikara, Alireza Fathi, Zbigniew Fischer, Ianand Wojna, Yang Song, Sergio Guadarrama, and Kevin Murphy. Tensorflow object detection api. *Code: github.com/tensorflow/models/tree/master/object\_detection*, CVPR 2017 (developing).
- [9] Marcin Kmiec and Andrzej Glowacz. Object detection in security applications using dominant edge directions. *Pattern Recognition Letters*, 52:72 – 79, 2015.
- [10] Tsung-Yi Lin, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, and C Lawrence Zitnick. Microsoft coco: Common objects in context. In *European conference on computer vision*, pages 740–755. Springer, 2014.
- [11] Roberto Olmos, Siham Tabik, and Francisco Herrera. Automatic handgun detection alarm in videos using deep learning. *Neurocomputing*, 275:66–72, 2018.
- [12] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. Faster r-cnn: Towards real-time object detection with region proposal networks. In *Advances in neural information processing systems*, pages 91–99, 2015.
- [13] Ali M. Reza. Realization of the contrast limited adaptive histogram equalization (clahe) for real-time image enhancement. *Journal of VLSI signal processing systems for signal, image and video technology*, 38(1):35–44, Aug 2004.
- [14] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv:1409.1556*, 2014.
- [15] Rohit Kumar Tiwari and Gyanendra K. Verma. A computer vision based framework for visual gun detection using harris interest point detector. *Procedia Computer Science*, 54:703–712, 2015.
- [16] Ivan Uroukov and Robert Speller. A preliminary approach to intelligent x-ray imaging for baggage inspection at airports. *Signal Processing Research*, 4:1–11, January 2015.
- [17] Zelong Xiao, Xuan Lu, Jiangjiang Yan, Li Wu, and Luyao Ren. Automatic detection of concealed pistols using passive millimeter wave imaging. In *2015 IEEE International Conference on Imaging Systems and Techniques (IST)*, pages 1–4. IEEE, 2015.

**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 8:  
APRENDIZAJE AUTOMÁTICO







# Measuring the Quality of Machine Learning and Optimization Frameworks\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Ignacio Villalobos, Javier Ferrer, Enrique Alba  
*Universidad de Málaga*  
Málaga, Spain  
{nacho, ferrer, eat}@lcc.uma.es

**Abstract**—Software frameworks are daily and extensively used in research, both for fundamental studies and applications. Researchers usually trust in the quality of these frameworks without any evidence that they are correctly build, indeed they could contain some defects that potentially could affect to thousands of already published and future papers. Considering the important role of these frameworks in the current state-of-the-art in research, their quality should be quantified to show the weaknesses and strengths of each software package.

In this paper we study the main static quality properties, defined in the product quality model proposed by the ISO 25010 standard, of ten well-known frameworks. We provide a quality rating for each characteristic depending on the severity of the issues detected in the analysis. In addition, we propose an overall quality rating of 12 levels (ranging from A+ to D-) considering the ratings of all characteristics. As a result, we have data evidence to claim that the analysed frameworks are not in a good shape, because the best overall rating is just a C+ for Mahout framework, i.e., all packages need to go for a revision in the analysed features. Focusing on the characteristics individually, maintainability is by far the one which needs the biggest effort to fix the found defects. On the other hand, performance obtains the best average rating, a result which conforms to our expectations because frameworks' authors used to take care about how fast their software runs.

**Index Terms**—maintainability, reliability, performance, security, quality



# Evaluation in learning from label proportions: an approximation to the precision-recall curve\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Jerónimo Hernández-González  
*Intelligent Systems Group*  
*University of the Basque Country UPV/EHU*  
Donostia, Spain  
jeronimo.hernandez@ehu.eus

**Abstract**—In the last decade, the learning from label proportions problem has attracted the attention of the machine learning community. Many learning methodologies have been proposed, although the evaluation with real label proportions data has hardly been explored. This paper proposes an adaptation of the area under the precision-recall curve metric to the problem of learning from label proportions. The actual performance is bounded by minimum and maximum approximations. Additionally, an approximate estimation which takes advantage of low-uncertain bags is proposed. The benefits of this proposal are illustrated by means of an empirical study.

**Index Terms**—Learning from label proportions, Weakly supervised classification, Evaluation, Precision-recall curve



# Identifying the Machine Learning Family from Black-Box Models\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Raül Fabra-Boluda, Cèsar Ferri, José Hernández-Orallo,  
Fernando Martínez-Plumed, M. José Ramírez-Quintana  
DSIC

*Universitat Politècnica de València*  
Valencia, Spain

{rafabbo,cferri,jorallo,fmartinez,mramirez}@dsic.upv.es

**Abstract**—We address the novel question of determining which *kind* of machine learning model is behind the predictions when we interact with a black-box model. This may allow us to identify families of techniques whose models exhibit similar vulnerabilities and strengths. In our method, we first consider how an adversary can systematically query a given black-box model (oracle) to label an artificially-generated dataset. This labelled dataset is then used for training different surrogate models (each one trying to imitate the oracle’s behaviour). The method has two different approaches. First, we assume that the family of the surrogate model that achieves the maximum Kappa metric against the oracle labels corresponds to the family of the oracle model. The other approach, based on machine learning, consists in learning a meta-model that is able to predict the model family of a new black-box model. We compare these two approaches experimentally, giving us insight about how explanatory and predictable our concept of family is.

**Index Terms**—machine learning families, black-box model, dissimilarity measures, adversarial machine learning



# Crowd Learning with Candidate Labeling: an EM-based Solution\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Iker Beñaran-Muñoz  
Basque Center for Applied Mathematics  
Bilbao, Spain  
ibenaran@bcamath.org

Jerónimo Hernández-González  
University of the Basque Country  
UPV/EHU  
Donostia, Spain  
jeronimo.hernandez@ehu.eus

Aritz Pérez  
Basque Center for Applied Mathematics  
Bilbao, Spain  
aperez@bcamath.org

**Abstract**—Crowdsourcing is widely used nowadays in machine learning for data labeling. Although in the traditional case annotators are asked to provide a single label for each instance, novel approaches allow annotators, in case of doubt, to choose a subset of labels as a way to extract more information from them. In both the traditional and these novel approaches, the reliability of the labelers can be modeled based on the collections of labels that they provide. In this paper, we propose an Expectation-Maximization-based method for crowdsourced data with candidate sets. Iteratively the likelihood of the parameters that model the reliability of the labelers is maximized, while the ground truth is estimated. The experimental results suggest that the proposed method performs better than the baseline aggregation schemes in terms of estimated accuracy.

**Index Terms**—Supervised classification, Crowdsourced labels, Weak supervision, Candidate labeling, Expectation-Maximization based method



# Aprendizaje automático con programación genética gramatical para la detección de patrones de diseño

Rafael Barbudo, José Raúl Romero, Sebastián Ventura  
Dpto. de Informática y Análisis Numérico, Universidad de Córdoba  
{rbarbudo, jrromero, sventura}@uco.es

**Resumen**—Las técnicas de aprendizaje automático han sido ampliamente utilizadas en diversos dominios. En el caso del desarrollo de software, la exploración de repositorios de código puede ayudar a descubrir buenas prácticas empleadas por otros desarrolladores. En este contexto, la detección automática de patrones de diseño puede generar múltiples beneficios relacionados con la mantenibilidad y la escalabilidad del software. Estos patrones son soluciones generales y reutilizables, aplicables a la resolución de un problema de diseño. No obstante, la falta de documentación suele dificultar su trazabilidad, provocando que sus implementaciones se pierdan entre miles de líneas de código.

Este trabajo propone un modelo de aprendizaje en dos fases para la detección automática de patrones de diseño. En primer lugar, un algoritmo de programación genética gramatical extrae aquellas propiedades que mejor describen al patrón. El uso de la gramática dota a la propuesta de una gran flexibilidad. A continuación, se construye el clasificador que permita detectar las implementaciones de dichos patrones. La propuesta ha sido empíricamente validada para tres patrones. Además, los resultados demuestran la competitividad del modelo frente a las propuestas actuales.

**Keywords**—detección de patrones de diseño, programación genética gramatical, clasificación asociativa, ingeniería inversa

## I. INTRODUCCIÓN

Un patrón de diseño (DP, *Design Pattern*) [1] es una solución efectiva y reutilizable, aplicable a la resolución de un determinado problema de diseño del software. Estos patrones no son soluciones definitivas que puedan ser directamente codificadas, pero proporcionan una plantilla sobre cómo solucionar dicho problema. Su uso da lugar a una serie de beneficios como (1) proporcionar un lenguaje y un marco de desarrollo común; (2) mejorar la legibilidad y la mantenibilidad del código; y (3) aportar soluciones probadas y demostradamente útiles. Esto ha propiciado que su aplicación se haya estandarizado para cualquier tipo de sistema software. A pesar de ello, los DPs no suelen aparecer explícitamente documentados y, por lo tanto, sus implementaciones quedan ocultas entre miles de líneas de código. Desde la perspectiva del mantenimiento del software, la identificación de estos patrones puede aportar varios beneficios. Por ejemplo, puede facilitar la comprensión y reusabilidad del código. En este contexto, la detección de patrones de diseño (DPD) se posiciona como una tarea de gran importancia en el campo de la ingeniería inversa del software. Dado que la inspección manual de código es una

labor subjetiva que requiere de un gran esfuerzo, la definición de métodos automáticos ha recibido un gran interés por la comunidad científica.

La mayoría de propuestas actuales tienen un punto en común: en mayor o menor medida, todas requieren de la inyección de conocimiento sobre la estructura y propiedades del DP a detectar. Este conocimiento representa la visión particular de un grupo de expertos y podría no ser suficiente para detectar las implementaciones o versiones realizadas por otros desarrolladores. Para paliar este problema, algunos métodos han introducido cierto grado de flexibilidad a la hora de llevar a cabo la detección. En este contexto, varios autores han propuesto el uso de técnicas de aprendizaje automático (ML, *Machine Learning*) que, a diferencia de otras, permiten analizar las implementaciones ya conocidas para inferir cuáles son las propiedades que mejor las describen. Estos métodos analizan el código en base a, o bien, una serie de métricas software, o de propiedades estructurales y categóricas.

En este trabajo se propone un modelo de dos fases que aplica técnicas de computación evolutiva y ML en el ámbito de la DPD. La primera fase es responsable de aprender cuáles son las propiedades que mejor describen a un patrón. Estas propiedades pueden referirse a (1) métricas software, como el acoplamiento entre clases; (2) propiedades de comportamiento, como la invocación de métodos; y (3) propiedades estructurales, como la relación de herencia entre clases. El encargado de realizar este aprendizaje es un algoritmo de programación genética gramatical [2] (G3P, *Grammar Guided Genetic Programming*). Dicho conocimiento se representa como un conjunto de reglas de asociación (AR, *Association Rule*) cuya estructura es conforme a una gramática libre de contexto (CFG, *Context-Free Grammar*). A continuación, en la segunda fase, se construye el detector a partir de dichas reglas. Para ello, antes es necesario definir un mecanismo de poda que asegure el uso exclusivo de las mejores reglas, así como de una estrategia que defina cómo emplearlas para llevar a cabo la detección.

La propuesta ha sido empíricamente validada para 3 tipos de DPs (*Singleton*, *Adapter* y *Factory Method*). Además, los resultados obtenidos se han comparado con los de la herramienta MARPLE [3] para los datos del repositorio DPB [4] (*Design Pattern detection Benchmark Platform*), el cual contiene implementaciones de DPs de 9 proyectos reales. Los resultados experimentales demuestran como, además de la flexibilidad y escalabilidad que otorga la gramática, el modelo propuesto

alcanza un gran rendimiento en términos de detección, siendo altamente competitivo frente a las propuestas actuales.

El resto del trabajo se organiza como sigue. La Sección II presenta el problema de la DPD. En la Sección III se presenta una visión general del modelo propuesto. A continuación, en la Sección IV, se describe la primera fase de la propuesta, es decir, el algoritmo de G3P para la extracción de ARs. La segunda fase, responsable de generar el detector, se explica en la Sección V. En la Sección VI la propuesta es validada empíricamente y comparada con otra propuesta actual. Por último, las conclusiones se recogen en la Sección VII.

## II. MARCO CONCEPTUAL

Los patrones de diseño se clasifican en función del tipo de problema de diseño que solucionan [1]: los *patrones de comportamiento* se centran en las interacciones entre clases y objetos; los *patrones creacionales* proporcionan una forma de crear objetos mientras se oculta la complejidad del proceso; y los *patrones estructurales* simplifican la composición de clases y objetos. El *Adapter* es un ejemplo del último grupo, cuyo objetivo es el de permitir el uso de una clase ya existente cuya interfaz no coincide con la requerida por el sistema. Cada DP describe un número fijo de roles. Un rol representa una determinada tarea que debe desempeñar un elemento del patrón. En sistemas software orientados a objeto, estos roles son desempeñados por clases o por sus instancias, o incluso interfaces en el caso de lenguajes como Java. Por ejemplo, el *Adapter* define cuatro roles diferentes: *adaptee*, *target*, *client* y *adapter*. El rol *adaptee* es desempeñado por la interfaz que necesita ser adaptada, mientras que *target* se refiere a la interfaz requerida por el sistema (*client*). Finalmente, el *adapter* define la correspondiente adaptación de los servicios proveídos por *adaptee* al formato requerido por *target*. Es importante destacar que estos roles podrían ser desempeñados por más de un elemento, dificultando el proceso de detección.

Un DP es una plantilla de una solución y, en consecuencia, pueden existir distintas implementaciones para un mismo patrón dependiendo del programador, requisitos del sistema, etc. Esto dificulta que una descripción estática de las propiedades de un patrón pueda detectar sus posibles variantes. En este contexto, un gran número de propuestas se basan en el uso de técnicas de *similarity scoring* [5], las cuales suelen representar la información estructural del patrón y del proyecto en forma de grafos. Por lo general, estos métodos buscan subestructuras que se correspondan con la del patrón dentro del grafo del proyecto. En contraposición, las técnicas de ML aprenden cuáles son las propiedades que mejor describen a dichos patrones mediante el análisis de repositorios de código. En [6], se construye un clasificador para llevar a cabo la detección mediante el análisis de una serie de implementaciones de patrones. Estos patrones se representan como vectores de características que están formados por  $n*k$  elementos, donde  $n$  es el número de métricas software consideradas y  $k$  es el número de roles. Por otra parte, MARPLE [3] usa propiedades estructurales y de comportamiento como entrada de las técnicas de ML. Como ya se mencionó, no existe ninguna

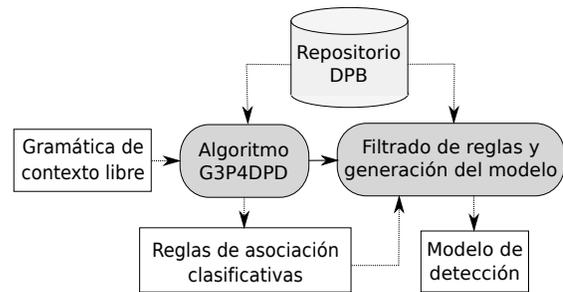


Figura 1: Modelo para la detección de patrones de diseño

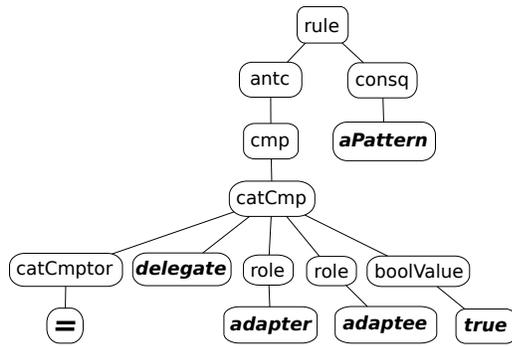
propuesta que considere tanto métricas software, como ambos tipos de propiedades simultáneamente durante el aprendizaje.

## III. MODELO PARA LA DPD

En este trabajo se presenta un modelo en dos fases para la DPD que combina el análisis de métricas software y de propiedades estructurales y de comportamiento del código (véase la Figura 1). El objetivo de la primera fase es aprender el conjunto de propiedades software que mejor describen al DP que se está estudiando. Para ello, se analiza el repositorio de código que alberga implementaciones de diversos patrones. Más concretamente, se ha empleado como caso de estudio el repositorio DPB ya que, a diferencia de otros repositorios como P-mart [7], DPB no solo contiene implementaciones correctas de patrones (instancias positivas), sino también implementaciones que no deberían ser consideradas patrones (instancias negativas). Estas últimas son similares a los patrones y, por lo tanto, podrían dar lugar a una detección errónea.

Un algoritmo basado en G3P (G3P4DPD) se encarga de aprender las propiedades que mejor describen a un DP y a sus variantes. Este algoritmo genera un conjunto de reglas conformes a la CFG y las evoluciona aplicando una serie de operadores genéticos. Esta CFG declara la sintaxis del lenguaje que permite expresar las propiedades del software y las restricciones que describen dichas instancias en forma de ARs [8]. Sea  $I = \{i_1, \dots, i_n\}$  un conjunto de *items*, una regla de asociación es una implicación del tipo  $A \rightarrow C$  donde  $A \subset I$ ,  $C \subset I$ , y  $A \cap C = \emptyset$ . El uso de esta CFG dota a la propuesta de una gran flexibilidad al permitir combinar propiedades software de diferente tipo como métricas software y propiedades estructurales y de comportamiento. Las reglas, que se obtienen en base a esta gramática se denominan reglas de asociación clasificativas [9] (CAR, *Class Association Rule*). Una CAR es un tipo de AR cuyo consecuente se limita a identificar la clase (implementar o no un DP).

Debido a su carácter descriptivo, estas reglas no se pueden utilizar directamente para llevar a cabo la detección. Además, dado que su número puede llegar a ser muy elevado, produciendo reglas redundantes y de baja calidad, hay que garantizar que únicamente se empleen las mejores reglas. Para ello se ha integrado un método de filtrado conocido como *database coverage* [9]. Por otra parte, es necesario definir una estrategia que establezca cómo utilizar dichas reglas para determinar si



(a) Ejemplo de genotipo



(b) Ejemplo de fenotipo

Figura 2: Ejemplo de representación de un individuo

una nueva instancia implementa o no un patrón. Para esta tarea se ha utilizado la estrategia definida por el algoritmo de clasificación asociativa CMAR [10].

#### IV. ALGORITMO DE G3P PARA LA GENERACIÓN DE AR

En esta sección se describe en detalle el algoritmo para la extracción de CARs. En primer lugar, se explica la CFG y la codificación de los individuos.

##### IV-A. Codificación de los individuos

Cada individuo del evolutivo se compone de dos elementos: (1) un genotipo, expresado en forma de árbol sintáctico, y (2) un fenotipo que representa la CAR. La Figura 2a muestra un genotipo de ejemplo, mientras que la Figura 2b muestra su correspondiente fenotipo, esto es, la regla.

La Figura 3 muestra las reglas de producción de la CFG, donde los símbolos no terminales se representan entre  $\langle \dots \rangle$  y los terminales en cursiva. El símbolo raíz, a partir del cual se inicia el proceso de derivación, es  $\langle rule \rangle$  y se deriva en  $\langle ant \rangle$  y  $\langle consq \rangle$ , los cuales representan al antecedente y consecuente de la regla, respectivamente. El antecedente está formado por una serie de comparaciones ( $\langle cmp \rangle$ ) que pueden ser numéricas ( $\langle numCmp \rangle$ ) o categóricas ( $\langle catCmp \rangle$ ). Independientemente del tipo, cada comparación está formada por un comparador, un operador, un conjunto de argumentos y un valor. Más concretamente, las comparaciones numéricas están formadas por un comparador numérico ( $>$ ,  $<$ ,  $\geq$  o  $\leq$ ), un operador numérico (p.ej. *NOC*), un rol como argumento del operador, y un valor constante (*const*). Nótese como estos operadores se corresponden con métricas software. Un ejemplo de comparación numérica podría ser “*NOC*(*target*) $<1$ ”, la cual indica que la clase que desempeña el rol *target* no tiene hijos (subclases). Por otra parte, las comparaciones categóricas se componen de un comparador categórico ( $=$  o  $!=$ ), un operador categórico (p.ej. *typeOf*), un número variable de roles como argumentos, y un posible valor asociado a dicho operador. En este caso, un ejemplo podría ser

```

<rule> ::= <antc> <consq>
<antc> ::= <cmp> | and <antc> <cmp>
<cmp> ::= <numCmp> | <catCmp>
<numCmp> ::= <numCmptor> <numOp> <role> <const>
<catCmp> ::= <catCmptor> isFinal <role> <boolValue>
           | <catCmptor> typeOf <role> <typeOfValue>
           | ...
<numCmptor> ::= > | < | > | <
<catCmptor> ::= = | !=
<numOp> ::= DIT | NOC | CBO | NOM
<role> ::= adapter | adaptee | target
<boolValue> ::= true | false
<typeOfValue> ::= class | absClass | intface | enum
...
<consq> ::= aPattern | notAPattern
    
```

Figura 3: Reglas de producción de la gramática

“*typeOf*(*target*)=*intface*”, la cual indica que el elemento que desempeña el rol *target* es una interfaz. El conjunto completo de operadores se recoge en la Tabla I. En relación al consecuente ( $\langle consq \rangle$ ), este solo puede ser derivado en *aPattern* o *notAPattern* para indicar si la regla hace referencia o no a un DP, respectivamente.

Es importante destacar como la mayoría de operadores categóricos se basan en los patrones de diseño elementales (en inglés, *elemental design patterns*) [11], micro patrones (en inglés, *micro patterns*) [12] y pruebas de patrones de diseño (en inglés, *design pattern clues*) [3], los cuales pueden ser vistos como operadores categóricos que comprueban si un fragmento de código satisface o no una determinada propiedad en base a valores de *true* o *false*. Por ejemplo, *Abstract Interface* es un patrón de diseño elemental que comprueba si un artefacto del código es abstracto o no. En algunos lenguajes como Java, un artefacto no solo puede ser una clase abstracta o concreta sino también una interfaz. Esto se podría solucionar añadiendo diferentes operadores como *isAbstract*, *isConcrete* o *isInterface*. No obstante, los predicados resultantes estarían fuertemente correlados y podrían introducir ruido al proceso de aprendizaje. En este contexto, la CFG permite el uso de operadores categóricos que pueden devolver múltiples valores. Por ejemplo, *typeOf* analiza un artefacto del código y devuelve un valor diferente según se trate de una clase concreta o abstracta, una interfaz o una enumeración. Este operador englobaría a los anteriores y, además de solucionar los problemas ya citados, su uso da lugar a reglas más compactas e interpretables.

##### IV-B. Descripción del algoritmo

El Algoritmo 1 muestra el esquema general del evolutivo. Como se puede apreciar, recibe cinco entradas: el número de iteraciones (*maxGen*), el tamaño de la población (*popSize*), el número de reglas a devolver (*extPopSize*), la gramática (*grammar*) y el repositorio de patrones (*repo*). Este repositorio está compuesto por un conjunto de instancias de DPs (positivas y negativas) y su código fuente. Cada una de estas instancias define los elementos que componen el patrón, así como los roles que desempeñan. El algoritmo devuelve una población externa (*extPop*) compuesta por las mejores reglas.

Tabla I: Operadores numéricos y categóricos

Operadores numéricos	
Signatura	Descripción
$NOM(R_1)$	Número de métodos de $R_1$
$NOC(R_1)$	Número de subclases directas de $R_1$
$DIT(R_1)$	Profundidad en el árbol de herencia de $R_1$
$RFC(R_1)$	Número de métodos que pueden ser invocados cuando una instancia de $R_1$ recibe un mensaje
Operadores categóricos	
Signatura	Descripción
$isSubclass(R_1)$	<i>true</i> si $R_1$ es una subclase, <i>false</i> en caso contrario
$isFinal(R_1)$	<i>true</i> si $R_1$ no puede ser heredado
$controlledInit(R_1)$	<i>true</i> si $R_1$ se instancia así mismo dentro de un bloque <i>if</i> o <i>while</i>
$staticField(R_1)$	<i>true</i> si $R_1$ tiene un campo estático
$staticFlag(R_1)$	<i>true</i> si $R_1$ tiene un campo estático y booleano
$conglomeration(R_1)$	<i>true</i> si $R_1$ declara algún método que llame al menos a otros 2 métodos de $R_1$
$returned(R_1, R_2)$	<i>true</i> si algún método declarado en $R_1$ devuelve un elemento del tipo $R_2$
$received(R_1, R_2)$	<i>true</i> si algún método declarado en $R_1$ recibe un elemento del tipo $R_2$ como argumento
$createObj(R_1, R_2)$	<i>true</i> si $R_1$ instancia a $R_2$
$delegate(R_1, R_2)$	<i>true</i> si $R_1$ invoca algún método de $R_2$
$sameElem(R_1, R_2)$	<i>true</i> si $R_1$ y $R_2$ son el mismo artefacto
$typeOf(R_1)$	Devuelve el tipo del artefacto que implementa a $R_1$ ( <i>class</i> , <i>absClass</i> , <i>enum</i> o <i>interface</i> )
$linkMethod(R_1, R_2)$	Devuelve <i>directOver</i> , <i>indirOver</i> , <i>directImpl</i> o <i>indirImpl</i> si $R_1$ directa o indirectamente sobrescribe o implementa un método de $R_2$ , <i>noLink</i> en cualquier otro caso
$linkArtefact(R_1, R_2)$	Devuelve <i>directInherit</i> , <i>indirInherit</i> , <i>directImpl</i> , <i>indirImpl</i> si $R_1$ directa o indirectamente extiende o implementa a $R_2$ , <i>noLink</i> en cualquier otro caso
$ctorVisibility(R_1)$	Devuelve la visibilidad del constructor menos restrictivo de $R_1$ , i.e. <i>private</i> , <i>protected</i> , <i>package</i> o <i>public</i>
$aggregation(R_1, R_2)$	Devuelve información de un atributo del tipo de $R_2$ declarado en $R_1$ en términos de su visibilidad y de su instanciabilidad.
$adapter(R_1, R_2, R_3)$	Devuelve si un método declarado ( <i>decl</i> ) o heredado ( <i>inhr</i> ) de $R_1$ , implementado de $R_3$ , delega en un método de $R_2$ , <i>noLink</i> en cualquier otro caso

Se comienza generando, de manera aleatoria,  $popSize$  individuos en base a las restricciones definidas por  $grammar$ . La población externa ( $extPop$ ) es inicializada al conjunto vacío. A continuación, se evalúan los individuos de  $pop$  en base al soporte (Ecuación 1). Esta métrica mide la frecuencia de aparición de una determinada regla en el conjunto de datos, siendo  $t$  el conjunto de transacciones en el conjunto de datos  $T$  que contiene al *itemset*  $X$ .

$$supp(X) = \frac{|\{t \in T; X \subseteq t\}|}{|T|} \quad (1)$$

A partir de este punto, el algoritmo, a lo largo de  $maxGen$  iteraciones, evoluciona a los individuos mediante la aplicación de operadores genéticos. En primer lugar, el operador de selección escoge  $popSize$  individuos de la unión entre  $pop$  y  $extPop$ . A continuación, el operador de cruce es aplicado, con una probabilidad prefijada, sobre pares de individuos para combinar sus genotipos. Por último, se aplica uno de dos posibles operadores de mutación. La selección se realiza de manera aleatoria, siendo ambos operadores equiprobables.

**Algoritmo 1:** Extracción de reglas de asociación

```

Entrada: maxGen, popSize, extPopSize, grammar, repo
Salida : extPop
pop ← generateRules(popSize, grammar)
extPop ← ∅
evaluate(pop, repo)
while generation < maxGen do
    pop ← select(pop ∪ extPop, popSize)
    pop ← crossover(pop)
    if random() < 0,5 then
        | pop ← diversityMutator(pop);
    else
        | pop ← dpdMutator(pop);
    end
    evaluate(pop, repo)
    extPop ← update(pop ∪ extPop, extPopSize)
    generation++
end
    
```

El primero (*diversityMutator*) es un operador genérico que promueve la diversidad entre los individuos, mientras que el segundo (*dpdMutator*) es específico del dominio de la DPD y busca generar reglas que cubran todas las instancias. Tras su aplicación,  $extPop$  es actualizada con las mejores reglas.

La población externa se actualiza uniendo y filtrando a los individuos de la población actual ( $pop$ ) y de la población externa de la generación anterior. En primer lugar, se ordenan las reglas en base a su confianza. La confianza (Ecuación 2) mide con qué frecuencia se cumple el consecuente ( $C$ ) en aquellas reglas en las que además se cumple el antecedente ( $A$ ). A continuación, estas reglas son filtradas en base al concepto de precedencia [9], esto es, dadas dos reglas  $R_1$  y  $R_2$ , se dice que  $R_1$  precede a  $R_2$  si y sólo si: (1)  $conf(R_1) > conf(R_2)$ ; (2)  $conf(R_1) = conf(R_2)$  y  $supp(R_1) > supp(R_2)$ ; o (3)  $conf(R_1) = conf(R_2)$ ,  $supp(R_1) = supp(R_2)$  y el número de atributos de  $R_1$  es menor que el de  $R_2$ .

En base a esto, si una regla  $A \rightarrow C$  precede a otra  $A' \rightarrow C'$  y  $A \subset A'$ , entonces  $A' \rightarrow C'$  es descartada. A continuación, se eliminan aquellas reglas con bajo soporte y confianza. Además, a partir del valor del estadístico  $\chi^2$  (Ecuación 3), se realiza un análisis estadístico para comprobar si el antecedente y consecuente de la regla están positivamente correlados. Así se garantiza que las reglas presenten implicaciones fuertes.

$$conf(A \rightarrow C) = \frac{supp(A \cup C)}{supp(A)} \quad (2)$$

$$\chi^2 = \frac{n * (lift(R) - 1)^2 * supp(R) * conf(R)}{(conf(R) - supp(R)) * (lift(R) - conf(R))} \quad (3)$$

$$\text{donde } lift(A \rightarrow C) = \frac{supp(A \cup C)}{supp(A) * supp(C)}$$



#### IV-C. Operadores genéticos

El selector escoge a los individuos que se utilizarán para generar otros nuevos. Más concretamente, se aplica un torneo binario, que toma aleatoriamente dos individuos y mantiene aquel con un mayor valor de *fitness*. Este proceso se repite hasta que se seleccionen *popSize* individuos.

A continuación, el operador de cruce selecciona, aleatoriamente, una comparación de los genotipos de dos individuos y las intercambia. Para localizar una comparación, el genotipo es recorrido en pre-orden hasta que se encuentra el símbolo  $\langle cmp \rangle$ . El final de dicha comparación se alcanza cuando se encuentra uno de los siguientes símbolos: *and*,  $\langle cmp \rangle$  o  $\langle consq \rangle$ . Por último, se devuelven los dos mejores individuos entre el conjunto de padres e hijos.

Finalmente, se aplica uno de los operadores de mutación. El primero (*diversityMutator*) selecciona un número de comparaciones y las reconstruye aleatoriamente desde  $\langle cmp \rangle$ . Este número se elige mediante una ruleta aleatoria que promueve las pequeñas modificaciones. Por otra parte, el segundo operador (*dpmMutator*) recorre todas las comparaciones y las niega con una determinada probabilidad, la inversa del número de comparaciones. Para negar una determinada comparación, el comparador se reemplaza por su opuesto (p.ej.  $>$  cambiaría a  $\leq$ ). Además, el terminal encargado de describir la clase también puede ser intercambiado con una probabilidad de 0,5. Este operador permite obtener reglas que describan tanto a la clase positiva como a la negativa. Así, por ejemplo, si la comparación “`typeof(target)=interface`” describe una propiedad que ocurre frecuentemente en las instancias positivas, es probable que “`typeof(target)!=interface`” describa a las negativas. Independientemente del operador aplicado, al final se devuelve el mejor individuo (padre o hijo).

#### V. CONSTRUCCIÓN DEL MODELO DE DETECCIÓN

Como se mencionó en la Sección III, en primer lugar se filtran las reglas de acuerdo al método de *database coverage*. Este filtro fue introducido inicialmente en el algoritmo CBA [9], y posteriormente utilizado en otros. Este método parte del conjunto de CARs, en orden descendente de precedencia, y del repositorio utilizado para generarlas. Para cada regla se realiza un pase sobre las instancias para encontrar a todas aquellas para las que se cumple el antecedente. Si la regla es capaz de clasificar correctamente al menos a una, se añade y se incrementa el contador de todas las instancias que cubre. Además, cuando una instancia es cubierta por un número de reglas, ésta se descarta. En el caso de que la regla no clasifique correctamente a ninguna instancia, ésta se elimina. Este proceso se repite hasta que todas las instancias hayan sido cubiertas o hasta que no queden más reglas.

Tras filtrar las reglas, es necesario definir la estrategia que empleará el modelo de detección para, a partir de las CARs restantes, identificar si un conjunto de clases está implementando o no un DP. Para este trabajo se ha empleado la estrategia definida por CMAR, de modo que cuando se recibe una nueva instancia se buscan todas aquellas reglas cuyo antecedente se satisface. Si todas tienen el mismo consecuente, se le asigna la

Tabla II: Configuración experimental

Parámetro	Valor
Número de generaciones	100
Tamaño de la población	100
Probabilidad de cruce	0,8
Número máximo de derivaciones	8
Umbral de soporte	0,01
Umbral de confianza	0,5
Umbral de $\chi^2$	3,841
Umbral de cobertura	4

etiqueta a la instancia. En caso contrario, las reglas se separan de acuerdo a sus consecuentes, y se calcula la  $\chi^2$  ponderada para determinar cuál es el grupo más representativo.

#### VI. VALIDACIÓN EMPÍRICA

El algoritmo G3P4DPD se ha desarrollado en Java tomando como base el *framework* JCLEC [13]. Para la obtención de métricas software se ha empleado la librería ckjm<sup>1</sup> (*Chidamber and Kemerer Java Metrics*). Por otra parte, las propiedades estructurales y de comportamiento se han extraído usando las librerías *Java Parser*<sup>2</sup> y *Javassist*<sup>3</sup>, las cuales extraen dichas propiedades del código fuente y del *bytecode*, respectivamente.

Las instancias usadas para validar la propuesta provienen del repositorio DPB, el cual ha sido creado por los autores de MARPLE y contiene instancias de 9 proyectos reales escritos en Java (p.ej. *Netbeans*). La Tabla II muestra la configuración empleada, donde los valores de los umbrales se han tomado de [10]. Es interesante destacar que el número máximo de derivaciones determina el tamaño del genotipo, es decir, de la regla. Este valor se ha fijado empíricamente en 8, ya que un valor superior difícilmente generaría reglas con un soporte admisible.

Nótese que la CFG ha sido parcialmente modificada para el estudio de cada DP. Cabe destacar que el uso exclusivo de los operadores más representativos por patrón reduce el espacio de búsqueda, mejorando la convergencia y minimizando el tiempo requerido para encontrar las mejores reglas. No obstante, experimentos previos han demostrado que el uso completo de la gramática no afecta al rendimiento del modelo de detección siempre que se incremente el número de generaciones. La Tabla III muestra qué operadores se han empleado para la detección de cada DP. Por una parte, los operadores categóricos se han seleccionado en base a su estructura y colaboraciones según lo definido por Gamma *et al.* [1]. Además, las micro-estructuras (en inglés, *micro-structures*), empleados por Zaroni *et al.* [3], también han sido usadas como referencia. Por otra parte, la selección de operadores numéricos para el *Factory Method* se ha realizado en base al estudio realizado por Issaoui *et al.* [14]. Para los demás casos, la selección de operadores se ha realizado en base a experimentos previos.

Antes de poder establecer un marco experimental, es necesario considerar que no existe ningún método que considere

<sup>1</sup>ckjm: <https://www.spinellis.gr/sw/ckjm>

<sup>2</sup>Java Parser: <https://javaparser.org>

<sup>3</sup>Javassist: <http://jboss-javassist.github.io/javassist/>

Tabla III: Operadores usados en la experimentación

	NOM	NOC	DIT	RFC	isFinal	isSubclass	controlledInit	staticField	staticFlag	conglomeration	returned	received	createObj	delegate	sameElem	typeOf	linkMethod	linkArtefact	ctorVisibility	aggregation	adapter
Singleton	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Adapter	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
F.Method	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

Tabla IV: Resultados experimentales

	Singleton	Adapter	Factory Method
Accuracy	0,9389 ± 0,0442	0,8554 ± 0,0199	0,8337 ± 0,0224
Precision	0,9283 ± 0,0833	0,8401 ± 0,0219	0,8157 ± 0,0273
Recall	0,9136 ± 0,0627	0,8797 ± 0,0252	0,8954 ± 0,0483
Specificity	0,9541 ± 0,0571	0,8308 ± 0,0261	0,7617 ± 0,0483
$F_1$	0,9179 ± 0,0559	0,8592 ± 0,0194	0,8529 ± 0,0226

Tabla V: Rendimiento de MARPLE

	Singleton	Adapter	Factory Method
Accuracy	0,9281	0,8588	0,8189
$F_1$	0,9026	0,8478	0,8340

todos los tipos de propiedades durante el aprendizaje. Como se mencionó anteriormente, MARPLE es una herramienta con una gran relevancia en el área, si bien no considera métricas software. A fin de poder medir el rendimiento de la propuesta, se ha realizado una validación cruzada estratificada de 5 particiones. Además, dado que el algoritmo G3P4DPD es estocástico, se han realizado 30 ejecuciones con diferentes semillas aleatorias. Igualmente, se ha de tener presente que MARPLE particiona internamente los datos, impidiendo la reproducibilidad de la experimentación sobre las mismas particiones.

La Tabla IV recoge los resultados obtenidos para los tres DPs. Debido al espacio limitado, para cada medida, únicamente se muestra su media y su desviación estándar. Por otra parte, la Tabla V recoge los resultados de MARPLE [3]. Además de las ventajas de flexibilidad y escalabilidad ya mencionadas, la propuesta alcanza valores competitivos en términos de las medidas de evaluación analizadas. Los valores de desviación estándar sugieren que el evolutivo es robusto y sus resultados están poco condicionados por la semilla aleatoria. También es interesante destacar como se alcanzan valores muy equilibrados entre las diferentes medidas.

## VII. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo propone un modelo de dos fases para la detección automática de patrones de diseño que combina técnicas de computación evolutiva y aprendizaje automático. En primer lugar, el algoritmo G3P4DPD extrae las propiedades que mejor describen a un patrón mediante el estudio del código. Este conocimiento se representa como un conjunto de reglas de asociación conformes a una gramática. A partir de estas reglas, en una segunda fase, se construye el modelo de detección. El

uso de la gramática dota a la propuesta de una gran flexibilidad ya que permite el estudio simultáneo de métricas software y otras propiedades estructurales y de comportamiento.

La propuesta ha sido empíricamente validada para tres patrones del repositorio DPB. Los resultados obtenidos han sido comparados con los de la herramienta MARPLE mostrando que, además de los beneficios cualitativos, la propuesta es competitiva y robusta en base a medidas objetivas de evaluación como *accuracy* y  $F_1$ . Así pues, el estudio conjunto de métricas software, así como de propiedades estructurales y de comportamiento resulta de gran interés al describir las implementaciones de los patrones.

Como trabajo futuro se planea incorporar nuevos operadores que den soporte a un mayor número de patrones de diseño y que mejoren los resultados de los ya soportados. Además, podría ser interesante integrar este modelo con IDEs existentes como Eclipse, y agregar capacidades para recomendar el desarrollo de un determinado patrón en un punto concreto del código de acuerdo con el conocimiento aprendido.

## REFERENCIAS

- [1] E. Gamma, R. Helm, R. Johnson, and J. Vlissides, *Design Patterns: Elements of Reusable Object-oriented Software*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1995.
- [2] R. I. McKay, N. X. Hoai, P. A. Whigham, Y. Shan, and M. O'Neill, "Grammar-based genetic programming: A survey," *Genetic Programming and Evolvable Machines*, vol. 11, no. 3-4, pp. 365–396, Sep. 2010.
- [3] M. Zanoni, F. Arcelli Fontana, and F. Stella, "On applying machine learning techniques for design pattern detection," *J. Syst. Softw.*, vol. 103, no. C, pp. 102–117, May 2015.
- [4] F. A. Fontana, A. Caracciolo, and M. Zanoni, "DPB: A benchmark for design pattern detection tools," in *2012 16th European Conference on Software Maintenance and Reengineering*, March 2012, pp. 235–244.
- [5] N. Tsantalis, A. Chatzigeorgiou, G. Stephanides, and S. T. Halkidis, "Design pattern detection using similarity scoring," *IEEE Trans. Softw. Eng.*, vol. 32, no. 11, pp. 896–909, Nov. 2006.
- [6] A. Cihada, S. Jalili, S. M. H. Hasheminejad, and M. H. Zangoeei, "Source code and design conformance, design pattern detection from source code by classification approach," *Appl. Soft Comput.*, vol. 26, no. C, pp. 357–367, Jan. 2015.
- [7] Y.-G. Guéhéneuc, "P-mart: Pattern-like micro architecture repository," *Proceedings of the 1st EuroPLOP Focus Group on Pattern Repositories*, 2007.
- [8] J. M. Luna, J. R. Romero, and S. Ventura, "Design and behavior study of a grammar-guided genetic programming algorithm for mining association rules," *Knowl. Inf. Syst.*, vol. 32, no. 1, pp. 53–76, Jul. 2012.
- [9] B. Liu, W. Hsu, and Y. Ma, "Integrating classification and association rule mining," in *Proceedings of the Fourth International Conference on Knowledge Discovery and Data Mining*, ser. KDD'98. AAAI Press, 1998, pp. 80–86.
- [10] W. Li, J. Han, and J. Pei, "CMAR: Accurate and efficient classification based on multiple class-association rules," in *Proceedings of the 2001 IEEE International Conference on Data Mining*, ser. ICDM '01. Washington, DC, USA: IEEE Computer Society, 2001, pp. 369–376.
- [11] J. M. Smith, *Elemental Design Patterns*, 1st ed. Addison-Wesley Professional, 2012.
- [12] J. Y. Gil and I. Maman, "Micro patterns in Java code," in *Proceedings of the 20th Annual ACM SIGPLAN Conference on Object-oriented Programming, Systems, Languages, and Applications*, ser. OOPSLA '05. New York, NY, USA: ACM, 2005, pp. 97–116.
- [13] S. Ventura, C. Romero, A. Zafra, J. A. Delgado, and C. Hervás, "JCLEC: a Java framework for evolutionary computation," *Soft Computing-A Fusion of Foundations, Methodologies and Applications*, vol. 12, no. 4, pp. 381–392, 2008.
- [14] I. Issaoui, N. Bouassida, and H. Ben-Abdallah, "Using metric-based filtering to improve design pattern detection approaches," *Innov. Syst. Softw. Eng.*, vol. 11, no. 1, pp. 39–53, Mar. 2015.

**XVIII Conferencia de la  
Asociación Española  
para la Inteligencia  
Artificial  
(CAEPIA 2018)**

CAEPIA 9:  
CLASIFICACIÓN Y  
AGRUPAMIENTO







# Learning Planning Action Models with Numerical Information and Logic Relationships using Classification Techniques\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

José Á. Segura-Muros, Raúl Pérez, Juan Fernández-Olivares  
*University of Granada*  
Granada, Spain  
{josesegmur,fgr,faro}@decsai.ugr.es

**Abstract**—The task of constructing a planning domain is difficult and requires time and vast knowledge about the problem to be solved. This paper describes PlanMiner-O3 a planning domain learner designed to alleviate this problem, based on the use of a classification algorithm, able to learn planning action models from noisy and partially observed logic states. PlanMiner-O3 is able to learn continuous numerical fluents as well as simple logical relations between them. Testing was realized with benchmark domains obtained from the International Planning Competition and the results demonstrate PlanMiner-O3's capabilities of learning planning domains.

**Index Terms**—



# Adapting Hierarchical Multiclass Classification to changes in the target concept\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Daniel Silva-Palacios, Cesar Ferri, M. Jose Ramirez-Quintana

*DSIC*

*Universitat Politècnica de València*

Valencia, Spain

dasilpa@posgrado.upv.es, {cferri,mramirez}@dsic.upv.es

**Abstract**—Machine learning models often need to be adapted to new contexts, for instance, to deal with situations where the target concept changes. In hierarchical classification, the modularity and flexibility of learning techniques allows us to deal directly with changes in the learning problem by readapting the structure of the model, instead of having to retrain the model from the scratch. In this work, we propose a method for adapting hierarchical models to changes in the target classes. We experimentally evaluate our method over different datasets. The results show that our novel approach improves the original model, and compared to the retraining approach, it performs quite competitive while it implies a significantly smaller computational cost.

**Index Terms**—Hierarchical, Classification, Adaptation, Novelty



# Clasificación ordinal de los grados de afectación de la enfermedad de Parkinson empleando imágenes de transportadores presinápticos de dopamina

J. Camacho-Cañamón \*  
julio.camacho@uco.es

María-Victoria Guiote  
UGC Medicina Nuclear §

Antonio-María Santos-Bueno  
UGC Medicina Nuclear §

Ester Rodríguez-Cáceres  
Equipo Provincial TICS §

Elvira Carmona-Asenjo  
UGC Medicina Nuclear §

Juan-Antonio Vallejo-Casas  
UGC Medicina Nuclear §  
jantonio.vallejo.sspa@juntadeandalucia.es

P. A. Gutiérrez \*  
pagutierrez@uco.es

C. Hervás-Martínez \*  
chervas@uco.es

\* *Dpto. de Informática y Análisis Numérico*  
*Universidad de Córdoba*  
Córdoba, España

§ *Hospital Universitario “Reina Sofía”*  
*Universidad de Córdoba. IMIBIC.*  
Córdoba, España

**Resumen**—La enfermedad de Parkinson se caracteriza por un descenso de la densidad de transportadores presinápticos de dopamina en los núcleos de la base. El método habitual de clasificación está basado en la observación y el análisis cualitativo de las imágenes obtenidas tras la administración de  $^{123}\text{I}$ -ioflupano al paciente que se va a diagnosticar. De esta forma, las técnicas recientes de neuroimagen, como la imagen dopaminérgica utilizando tomografía computarizada por emisión de fotón único (SPECT-CT) con  $^{123}\text{I}$ -ioflupano (DaTSCAN®), han demostrado detectar la enfermedad, incluso en etapas tempranas. Sin embargo, los comités internacionales recomiendan un análisis cuantitativo, asociado a la construcción de modelos de apoyo que complementen el diagnóstico visual. El objetivo del presente estudio es establecer un sistema de apoyo a la decisión, mediante la clasificación ordinal de las imágenes asociadas a los diferentes grados de afectación de la enfermedad mediante técnicas de aprendizaje automático. La base de datos utilizada está formada por 316 estudios realizados a pacientes entre septiembre de 2015 y mayo de 2018, distribuidos en tres grupos: 191 no padecen la enfermedad de Parkinson, 55 la padecen con un nivel de afectación leve y 70 con un nivel de afectación grave. Tras la administración intravenosa de 5 mCi (185 MBq), se realizó una SPECT-CT, preprocesando y normalizando espacialmente las imágenes. Como clasificador ordinal utilizamos un método de regresión logística, que nos permite obtener las características (vóxeles de la imagen) más informativas para la tarea de clasificación. El mejor modelo alcanzó un error absoluto medio máximo (MMAE) de 0,4857, tras la aplicación de un diseño experimental de tipo 5-fold. El análisis de los vóxeles más informativos, de acuerdo con el modelo obtenido, destaca regiones del cerebro que no son consideradas habitualmente por los especialistas para el

diagnóstico visual.

**Index Terms**—Enfermedad de Parkinson, SPECT-CT, aprendizaje automático, clasificación ordinal, regresión logística ordinal, imagen médica

## I. INTRODUCCIÓN

Una de las características neuropatológicas de la enfermedad de Parkinson es un sustancial descenso de dopamina en los núcleos basales (caudado y putamen) debido a la disminución progresiva de la densidad de transportadores presinápticos [1]. La densidad de transportador presináptico de dopamina se puede detectar mediante técnicas de neuroimagen, que actualmente constituyen una práctica ordinaria en el diagnóstico de trastornos neurodegenerativos como la enfermedad de Parkinson. El  $^{123}\text{I}$ -ioflupano (DaTSCAN®, General Electric Healthcare Limited, Little Chalfont. Bucks HP79NA U.K.) es un radiofármaco, ampliamente empleado para este fin, que se une a los transportadores presinápticos de dopamina en el cuerpo estriado y permite evaluar la densidad de estos con alta sensibilidad [2].

Actualmente, se combinan sistemas de cuantificación semi-automáticos, que analizan las imágenes, con los diagnósticos visuales dependientes de un observador especializado y, juntos, son capaces de distinguir entre las clases: control, patológico con nivel de afectación leve y patológico con nivel de afectación grave. En el caso del diagnóstico de la enfermedad de Parkinson, se aborda el problema con un enfoque clásico, es decir, mediante la cuantificación de la pérdida de dopamina neuronal en el estriado [3]. En este sentido, el Comité de la Asociación Europea de Medicina Nuclear y Neuroimagen recomienda el análisis cuantitativo, asociado a la construcción de modelos computacionales de apoyo que complementen el diagnóstico visual [4]. Debido a que la enfermedad de Parkinson afecta, fundamentalmente, a las neuronas que manejan

Este trabajo ha sido realizado gracias al apoyo económico derivado de los proyectos TIN2017-85887-C2-1-P y TIN2017-90567-REDT del Ministerio de Economía, Industria y Competitividad de España y, también, por el apoyo de los fondos FEDER de la Unión Europea. También se agradece a la Universidad de Córdoba por haber premiado al proyecto “Clasificación y evaluación automática de los grados de parkinson” UCO-SOCIAL-INNOVA, en el marco del cual se realiza este trabajo, en el III Plan Propio Galileo de Innovación y Transferencia. Los autores agradecen a NVIDIA Corporation la cesión de recursos computacionales a través del GPU Grant Program.

dopamina como neurotransmisor principal, la mayoría de los modelos analíticos asociados al uso de ioflupano se centran en el cuerpo estriado. En este estudio, nos centraremos en el cuerpo estriado, pero incluiremos el resto de la imagen cerebral en el análisis, dado que una hipótesis fundamental de este trabajo plantea la existencia de otras zonas del cerebro en las que los efectos de la dopamina también pueden ayudar a realizar una clasificación más precisa.

La mayoría de trabajos abordan el problema de clasificación binaria (pacientes de control y patológicos), utilizando imágenes funcionales, y empleando técnicas de aprendizaje automático basadas en regiones de interés (caudado y putamen) [5]. El análisis basado en estas regiones generalmente se justifica en que hay pérdida de actividad dopaminérgica en el putamen en relación con el caudado para los enfermos de Parkinson. Sin embargo, el rendimiento de modelos de clasificación binaria que utilizan solo estas regiones de interés es limitado. En primer lugar, no está claro si una variable aleatoria asociada a un vóxel (unidad volumétrica mínima de la imagen) es significativamente importante para la tarea de clasificación. Ciertos vóxeles, dentro de estas regiones, pueden sufrir una mayor pérdida de transportador de dopamina que otros y, por lo tanto, pueden ser más informativos. En segundo lugar, no se debe asumir que solamente el caudado y el putamen sean las zonas a partir de las cuáles se extraigan las características (vóxeles) que utilice el clasificador.

Se sabe que las estructuras extraestriadas están involucradas en la enfermedad de Parkinson. Y que, además, el globo pálido está involucrado en los subtipos de la enfermedad de Parkinson [6], así que esta región cerebral también se ha incluido en nuestro análisis. El hecho de incluir todos los vóxeles de estas regiones como características discriminantes reporta mayor interés que asumir *a priori* que ciertos vóxeles son los más importantes, según conocimiento especializado. Por lo tanto, nuestro estudio desarrolla un algoritmo basado en vóxeles en lugar de basado en las regiones de interés clásicas.

El modelo de aprendizaje automático utilizado para clasificación será una regresión logística ordinal regularizada [7]. Con la regularización del modelo se pretende minimizar el número de características que intervienen en la clasificación, es decir, vóxeles, mediante la minimización del valor absoluto de los coeficientes que tienen asociados. El modelo es una combinación lineal de los coeficientes asociados a los vóxeles, cuyo valor se emplea para calcular las probabilidades de pertenecer a las tres clases: normal (clase 1), patológico con nivel de afectación leve (clase 2) y patológico con nivel de afectación grave (clase 3). Así, mediante esta metodología estimaremos la probabilidad de pertenencia a una de las tres clases asociadas al nivel de afectación de la enfermedad de Parkinson. Además de la clasificación, otro de los objetivos de este estudio es reconocer cuáles son los “vóxeles informativos”, término que empleamos para denotar aquellos que son significativamente útiles para la clasificación, es decir, más determinantes para construir el clasificador. Estos serán un subconjunto de todos los vóxeles analizados de la imagen completa y, previsiblemente, también un subconjunto de todos

los vóxeles afectados por la enfermedad de Parkinson. Con el fin de crear modelos de clasificación aún más sencillos se evaluará el uso de un selector de características previo (ReliefF [8]).

Los resultados indican que el diagnóstico utilizando todos los vóxeles de la imagen es factible, obteniéndose un rendimiento aceptable para la complejidad del problema abordado. Además, se detectan vóxeles útiles para la tarea de clasificación en regiones que no habían sido previamente consideradas en la literatura. Por último, el uso del selector de características ReliefF no mejora el rendimiento del clasificador.

En la Sección II se realizará una revisión de los trabajos relacionados con el problema de clasificación de pacientes de parkinson. Posteriormente, en la Sección III, se detallarán los conjuntos de datos utilizados y su forma de obtención, así como la metodología empleada para generar los modelos de clasificación. Para concluir, en la Sección IV, se mostrarán los resultados obtenidos y se realizará una discusión de los mismos. La Sección V expondrá las conclusiones obtenidas tras este trabajo y las posibles futuras mejoras.

## II. ESTADO DEL ARTE

Son muchos los métodos basados en aprendizaje automático utilizados en los sistemas de apoyo al diagnóstico médico, como pueden ser las máquinas de vectores soporte (MVS), la regresión logística (RL), los árboles de decisión, las redes bayesianas o las redes neuronales. Todas ellas son importantes en tanto en cuanto puedan ayudar al médico clínico a realizar un diagnóstico temprano de la enfermedad, permitan planificar su tratamiento y posibiliten la monitorización de la progresión de la enfermedad [5]. Estas metodologías están siendo ampliamente utilizadas en neuroimagen [9], debido a las siguientes ventajas: permiten la clasificación a nivel de individuo más que a nivel de grupo, por lo que los resultados tienen un alto potencial de traslación a la práctica clínica; son técnicas multivariantes y supervisadas que tienen en cuenta las características de los patrones (imágenes volumétricas, en este caso) distribuidas en un espacio de características complejo de alta dimensionalidad para entrenar el modelo de clasificación y, una vez entrenado, poder clasificar nuevos pacientes en función del modelo obtenido.

Algunos trabajos en los que se utilizan las MVS como clasificador binario [10], [11] están basados en extraer los vóxeles correspondientes al estriado. En [10], los autores realizan una descomposición de datos utilizando mínimos cuadrados parciales (*Partial Least Squares*) seguida por la utilización del clasificador MVS. En [11], los autores utilizan, una vez extraídos los vóxeles, un clasificador MVS lineal, contando con 208 imágenes DaTSCAN y utilizando máscaras para la selección de vóxeles.

Por otra parte, el modelo de RL determina la probabilidad de tener la enfermedad de Parkinson para un paciente, utilizando como características explicativas los vóxeles de las imágenes normalizadas. Esta metodología puede ser útil también para clasificar pacientes en diferentes categorías de riesgo de padecer la enfermedad, como sugieren algunos estudios utilizando



SPECT-CT en imágenes con  $^{123}\text{I}$ -ioflupano, que representan la progresión de degeneración dopaminérgica de la enfermedad de Parkinson [12].

### III. MATERIAL Y MÉTODOS

#### III-A. Material

Con el fin de evaluar la metodología propuesta en este trabajo, hemos utilizado los datos de 316 estudios con  $^{123}\text{I}$ -ioflupano en pacientes derivados para evaluación de trastornos del movimiento realizados en el Hospital Universitario ‘Reina Sofía’ de Córdoba, en el periodo que va desde septiembre de 2015 hasta mayo de 2018. Los pacientes se distribuyen en tres clases: 191 no padecen la enfermedad de Parkinson (normal, clase 1), 55 padecen la enfermedad de Parkinson con un nivel de afectación leve (patológico, clase 2) y 70 padecen la enfermedad de Parkinson con un nivel de afectación grave (patológico, clase 3). La relación entre los valores muestrales asociados a padecer o no la enfermedad en cualquier de sus niveles de afectación se acercan a la relación poblacional entre dichas categorías. El diagnóstico definitivo se establece por la combinación de pruebas clínicas y complementarias realizadas por la Unidad de Neurología del centro hospitalario. La media de edad de los pacientes es de 70.46 años (35-89) con una desviación típica de 11,85 años. Las imágenes de SPECT-CT se adquieren según el protocolo indicado en [13].

Tres especialistas de la Unidad de Medicina Nuclear, han procesado, interpretado y evaluado las imágenes. La evaluación visual se ha establecido considerando exclusivamente el criterio normal y patológico en función del grado basándose en criterios comunes preestablecidos [14], y después de llegar a un informe de consenso entre los tres especialistas. Se consideró que un paciente era normal cuando, en la imagen volumétrica correspondiente a su estudio, aparecía una simetría bilateral en los núcleos basales, caudado y putamen; enfermedad de Parkinson con un nivel de afectación leve, cuando había una asimetría o reducción completa en la actividad del putamen; y con un nivel de afectación grave cuando había una ausencia bilateral de actividad en el caudado y putamen. Véase la figura 1, donde se muestra una imagen de un paciente normal en 1(a), la de un paciente patológico con un nivel de afectación leve en 1(b) y la de un paciente patológico con un nivel de afectación grave en 1(c).

#### III-B. Preprocesado de la imagen

El preprocesado de las imágenes consta de dos partes: *normalización espacial* y *recuperación de información*. Las imágenes suministradas inicialmente están sin procesar, por tanto hay que normalizarlas espacialmente, de forma que los mismos vóxeles representen las mismas características en todos los estudios. Para ello se utiliza el *software* PETRA [15] basado en el *framework* SPM8 [16], que permite leer y reunir varios archivos DICOM para formar una sola imagen espacial. Para realizar la normalización espacial se coordinan los ejes tridimensionales con la comisura anterior cerebral de la imagen, cuyas coordenadas están almacenadas en el

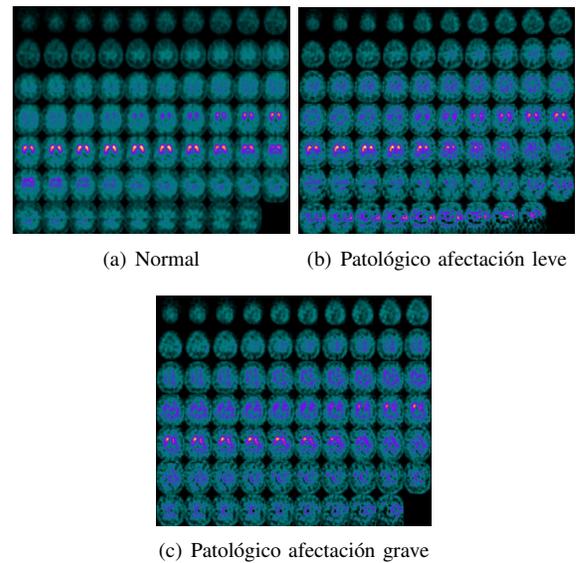


Figura 1. Imágenes de pacientes normal (a), patológico con nivel de afectación leve (b) y patológico con nivel de afectación grave (c).

formato DICOM de la imagen. No obstante, el método de normalización espacial se explica con detalle en [15].

Aplicando esta normalización a cada imagen, se obtiene una matriz tridimensional de  $79 \times 95 \times 69$  vóxeles, es decir,  $V = 517,845$  vóxeles por cada estudio. Este elevado número de vóxeles implica que es necesario aplicar técnicas de aprendizaje automático preparadas para un gran número de características. Tras la normalización espacial, es necesario hacer una búsqueda de valores perdidos en los vóxeles de cada imagen. Los valores perdidos serán sustituidos por la media de los valores que tienen los vóxeles del eje horizontal en el que se encuentra el valor perdido. A este proceso se le conoce como recuperación de información. Una vez preprocesadas las imágenes utilizaremos todos los vóxeles de cada paciente como características de entrada al clasificador, como se explica en la siguiente sección.

#### III-C. Metodología

*III-C1. Notación y terminología:* En primer lugar, definiremos algunos términos y notaciones. La imagen del paciente  $i$ -ésimo está representada por el vector  $\mathbf{x}_i$ , donde  $i = 1, \dots, N$ , siendo  $N$  el número de estudios (316). Si  $v$  es la posición de un vóxel concreto en una imagen,  $v = 1, \dots, V$ , entonces  $\mathbf{x}_i(v)$  es el valor del vóxel  $v$  en la imagen del paciente  $i$ .

Leyendo la imagen de cada paciente  $i$  como una serie o conjunto de valores (vóxeles), la imagen  $\mathbf{x}_i$  se puede entender como un vector de tamaño  $V \times 1$ . Por tanto,  $\mathbf{x}_i(v)$  es la componente  $v$  del vector de dimensiones  $V \times 1$ . Dicho de otra forma, cualquiera de estos vectores (de tamaño  $V \times 1$ ) serviría para reconstruir una imagen  $79 \times 95 \times 69$ , la cual puede ser representada como una imagen 3D. De este modo, podremos considerar y visualizar un vector concreto.

Respecto a la clase de cada paciente  $i$ , la representaremos como una variable categórica  $y_i$  con tres categorías ordinales,

siendo  $y_i = 1$  si el paciente  $i$  pertenece al grupo de control (normal),  $y_i = 2$  si el paciente  $i$  padece enfermedad de Parkinson con un nivel de afectación leve, e  $y_i = 3$  indicará que el nivel de afectación es grave.

Suponemos que este conjunto de patrones de entrenamiento es una realización de un conjunto de  $V$  variables aleatorias independientes e idénticamente distribuidas, así como de la variable asociada a la clase  $y_i$  de cada paciente. El conjunto de datos será representado por  $D = \{(\mathbf{x}_i, y_i)\}, i = 1, \dots, N$ . El número de pacientes de cada una de las clases de interés (normal, afección leve y afección grave) será denotado como  $N_1, N_2$  y  $N_3$ , respectivamente.

*III-C2. Regresión logística ordinal regularizada:* Consideraremos un modelo de RL ordinal [17] para estimar la probabilidad de que un paciente tenga un determinado nivel de afectación de la enfermedad de Parkinson, es decir, el modelo estima la probabilidad condicional  $P(y_i = q|\mathbf{x}_i), q \in \{1, 2, 3\}$ .

Suponemos que, al ser la variable dependiente ordinal, el mejor modelo que se ajusta a la nube de puntos es un modelo de RL ordinal. Como ya se mencionó, una aproximación similar, pero para clasificación binaria, [5] ha sido empleada para la detección de la enfermedad de Parkinson.

El modelo de RL ordinal (de forma más específica, *Proportional Odds Model*, POM, [17]) es un modelo de umbral [18] que modela la respuesta categórica ordinal mediante una función lineal de proyección  $f(\mathbf{x}_i, \theta)$  común para todas las clases y un vector de umbrales  $\beta$ . Debido a que en nuestro problema hay tres clases, se cumple  $\beta = \{b_1, b_2\}$ , siendo  $b_1 < b_2$ . La probabilidad *a posteriori* de pertenencia a una clase se obtiene modelando la probabilidad de pertenencia acumulada a toda clase menor o igual a la evaluada:

$$P(y_i \leq q|\mathbf{x}_i, \hat{\mathbf{s}}) = \sum_{j=1}^q P(y_i = j|\mathbf{x}_i, \hat{\mathbf{s}}),$$

$$P(y_i = q|\mathbf{x}_i, \hat{\mathbf{s}}) = P(y_i \leq q|\mathbf{x}_i, \hat{\mathbf{s}}) - P(y_i \leq (q-1)|\mathbf{x}_i, \hat{\mathbf{s}}),$$

donde  $\hat{\mathbf{s}} = \{\theta, \beta\}$  incluye todos los parámetros libres del modelo. Las probabilidades acumuladas se aproximan mediante la inversa de la función  $\logit$  (o función sigmoide):

$$P(y_i \leq q|\mathbf{x}_i, \hat{\mathbf{s}}) = \sigma(f(\mathbf{x}_i, \theta)) = \frac{1}{1 + \exp(-f(\mathbf{x}_i, \theta))},$$

para  $q = \{1, 2\}$ . Por definición,  $P(y_i \leq 0|\mathbf{x}_i, \hat{\mathbf{s}}) = 0$  y  $P(y_i \leq 3|\mathbf{x}_i, \hat{\mathbf{s}}) = 1$ . La función de proyección es lineal, por lo que  $f(\mathbf{x}_i, \theta) = \theta^T \cdot \mathbf{x}_i$ . Por ello, la expresión final del modelo es:

$$\begin{aligned} P(y_i = 1|\mathbf{x}_i, \hat{\mathbf{s}}) &= \sigma(\theta^T \cdot \mathbf{x}_i - b_1), \\ P(y_i = 2|\mathbf{x}_i, \hat{\mathbf{s}}) &= \sigma(\theta^T \cdot \mathbf{x}_i - b_2) - \sigma(\theta^T \cdot \mathbf{x}_i - b_1), \\ P(y_i = 3|\mathbf{x}_i, \hat{\mathbf{s}}) &= 1 - \sigma(\theta^T \cdot \mathbf{x}_i - b_2). \end{aligned} \quad (1)$$

Para la estimación de los parámetros  $\hat{\mathbf{s}} = \{\theta, \beta\}$ , se utiliza el método de máxima verosimilitud, que minimiza la siguiente función de entropía cruzada:

$$L(\mathbf{s}, D) = -\frac{1}{N} \sum_{i=1}^N \sum_{q=1}^3 [[y_i = q]] \ln(P(y_i = q|\mathbf{x}_i)),$$

donde  $[[c]] = 1$  si la condición  $c$  es cierta ( $[[c]] = 0$ , en caso contrario).

Es bien conocido que un sobre-ajuste del conjunto  $D$  puede incurrir en un modelo con varianza mayor, empobreciendo el rendimiento del conjunto de *test*. Una forma de controlar este fenómeno de sobre-entrenamiento es el uso de un término de regularización, que evita valores altos de los coeficientes, reduciendo la varianza y aumentando el sesgo, a costa de empeorar el ajuste al conjunto de entrenamiento. Para ello, modificamos la función de error de la siguiente forma:

$$L_2(\mathbf{s}, D) = L(\mathbf{s}, D) + \lambda \cdot \sum_{i=1}^V \theta_i^2, \quad (2)$$

donde  $\lambda$  es el parámetro de regularización. Dicho parámetro, que toma valores positivos, representa la importancia que se le da a la regularización frente a la minimización del error y debe ser ajustado por el investigador (normalmente en base a algún tipo de proceso de validación). Utilizando las Ecuaciones (1) y (2), el aprendizaje del modelo puede realizarse mediante las derivadas analíticas de  $L_2(\mathbf{s}, D)$  con respecto a cada uno de los parámetros  $s_i \in \{\theta, \beta\}$ , mediante algún método de optimización (en el caso de la RL, se suelen emplear métodos de segundo orden). Estas derivadas pueden consultarse en [19]. Tal y como se discute en [20], la formulación de este modelo de RL ordinal se ajusta a una función de pérdida de tipo *Immediate-Threshold* (umbrales adyacentes), de forma que, para cada ejemplo etiquetado con  $y_i$ , solo se penaliza el error que cometen los umbrales que limitan el segmento correcto (es decir,  $b_{y_i}$  y  $b_{y_i-1}$ ).

A partir de este modelo de RL, se pueden obtener, lo que hemos denominado, *Componentes Logísticas Principales* (CLP), que son aquellos vóxeles cuyo respectivo coeficiente  $\theta_i$  es más elevado en valor absoluto. Es decir, estos vóxeles son los que más han influido en la función  $f(\mathbf{x}_i, \theta)$ , por lo que son los vóxeles más importantes para clasificar el sujeto en cualquiera de las tres clases consideradas. Las CLP tienen una estructura de componentes binarias de dimensión  $V \times 1$ , donde 1 significa que ese vóxel es relevante y 0 que no lo es. Por lo tanto, como hemos explicado previamente, se pueden llegar a representar como una imagen 3D. Así, se puede apreciar qué zonas son las que más afectan a la clasificación según el nivel de afectación de la enfermedad de Parkinson, como se ilustrará en el apartado de resultados.

*III-C3. Diseño experimental:* Para la evaluación de la bondad del modelo, aplicamos un diseño experimental de validación cruzada de tipo *5-fold*. Los pliegues o *folds* se crearán de forma estratificada, es decir, manteniendo la proporción original de patrones de pacientes normales, leves y graves.

Por cada una de las 5 particiones, realizaremos el aprendizaje estimando el mejor valor para el parámetro  $\lambda$  mediante una validación cruzada anidada: el conjunto de entrenamiento (que incluye 4 pliegues) se divide, de nuevo, en 2 conjuntos estratificados, aplicando un diseño de tipo *2-fold* por cada valor del parámetro  $\lambda$  que va a ser explorado. Los valores explorados para  $\lambda$  son los siguientes  $\lambda \in \{10^{-3}, 10^{-2}, \dots, 10^3\}$ .



A la hora de realizar el ajuste de  $\lambda$  elegimos el valor que produzca un menor error de validación. En concreto, utilizamos la función de error *MMAE* (*Maximum Mean Absolute Error* [21], la cual es específicamente adecuada para problemas desequilibrados de clasificación ordinal). El *MAE* es una medida de error que tiene en cuenta la ordinalidad de la variable objetivo,  $MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y_i^*|$ , donde  $|y_i - y_i^*|$  es la distancia absoluta entre las etiquetas reales y predichas. El *MAE* varía desde 0 hasta 2 (que sería la máxima desviación en número de categorías en nuestro problema). Sin embargo, en problemas desequilibrados, las clases más frecuentes pueden dominar el error *MAE*, enmascarando un rendimiento pobre para las clases menos comunes. Es por ello que el *MMAE* se define de la siguiente forma,  $MMAE = \max\{MAE_1, MAE_2, MAE_3\}$ , donde  $MAE_q$  es el error *MAE* teniendo en cuenta solo los patrones de la clase  $q$ :  $MAE_q = \frac{1}{N_q} \sum_{i=1}^N |y_i - y_i^*|$ ,  $q \in \{1, 2, 3\}$ .

Con la intención de mostrar la mejora obtenida usando todos los vóxeles de las imágenes en lugar de usar solamente las regiones descritas por los especialistas, se han realizado pruebas con la misma experimentación, pero seleccionando previamente aquellas variables que los especialistas sitúan en las zonas estriales del cerebro.

Igualmente, se han aplicado técnicas de selección de características de tipo filtro, en concreto, el método ReliefF [8]. Estas son aplicadas como paso previo al entrenamiento del modelo con el fin de vislumbrar aquellas características con las que el modelo podría obtener mejores resultados.

Por último, una vez estimado el error mediante el proceso *5-fold*, estimaremos las CLP. Para ello, repetiremos el entrenamiento del modelo, pero considerando todos los pacientes disponibles, con el fin de obtener el mejor modelo posible. De nuevo, se aplicará una validación cruzada anidada de tipo *2-fold* que ajuste el mejor valor de  $\lambda$  en la RL ordinal. En nuestro experimento, para establecer las CLP, escogemos el 0,50 % de los vóxeles (2590) cuyo  $\theta_i$  es mayor en valor absoluto.

#### IV. RESULTADOS

Cada uno de los subconjuntos de entrenamiento generados en el procedimiento *5-fold* se utiliza para calcular la matriz de confusión de su respectivo conjunto de generalización. La suma de las matrices de confusión generadas para cada subconjunto de generalización será el resultado final del modelo, y a partir de ella se calculará el *MMAE* completo. En la tabla I se muestran todos los resultados obtenidos empleando distintas metodologías: considerar todos los vóxeles (y dejar que la regularización seleccione los más importantes), considerar solo las regiones de interés determinadas por los expertos (caudado y putamen) y considerar el método ReliefF de selección de características manteniendo un 5 %, 2 % y 1 % de los vóxeles originales. La tabla incluye una referencia a la subfigura de la Figura 2 que incluye la matriz de confusión correspondiente.

Los resultados demuestran que usando todos los vóxeles se consigue el mejor clasificador en *MMAE* y en *CCR*. También cabe destacar que usando las regiones de interés que los especialistas han indicado, se consigue un *MMAE* igual al que

Tabla I  
ANÁLISIS DE RESULTADOS EN FUNCIÓN DE LOS VÓXELES CONSIDERADOS

Vóxeles	Figura	Nº Vóxeles	<i>MMAE</i> ↓	<i>CCR</i> ↑
Todos	2(a)	517845	<b>0,4857</b>	<b>0,7532</b>
Caudado y putamen	2(b)	3267	0,6727	<b>0,7532</b>
ReliefF (5 %)	2(c)	25892	0,6000	0,7468
ReliefF (2 %)	2(d)	10356	0,6727	0,7247
ReliefF (1 %)	2(e)	5178	0,7091	0,7342

se consigue empleando ReliefF y seleccionando el 2 % de las características más representativas. Sin embargo, el número de vóxeles empleados analizando las regiones de interés es una tercera parte de los que se utilizan con el selector. Esto indica que ReliefF no es adecuado para este problema, posiblemente por estar pensado para clasificación nominal.

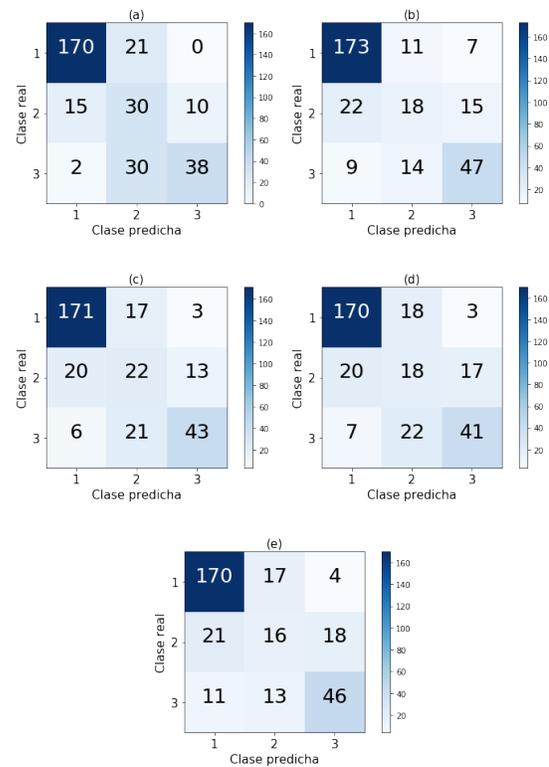


Figura 2. Matrices de confusión de los resultados de cada experimento.

Para finalizar, se visualizan los vóxeles más informativos de la imagen (CLP) tras entrenar los clasificadores con todos los datos y todos los vóxeles (ver Figura 3). Como puede apreciarse, existe una gran cantidad de vóxeles importantes agrupados en los propios núcleos basales, algo que era de esperar antes de realizar la representación. No obstante, debemos prestar especial atención a aquellas zonas que, sin pertenecer a las regiones de interés clásicas, también son muy relevantes para el modelo de RL ordinal en su tarea de clasificación. Estas lesiones extraestriales coinciden con la tendencia de otros estudios (resonancia magnética, por ejemplo) a evidenciar alteraciones en áreas cerebrales fuera

del estriado. Se corresponden a pequeñas zonas corticales, de predominio temporal y en la región media del lóbulo parietal.

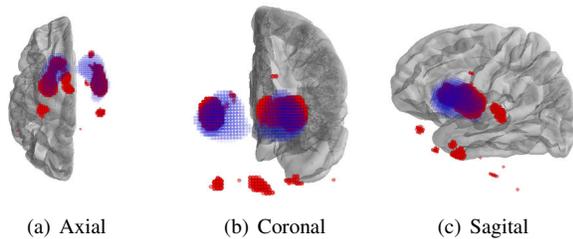


Figura 3. Representación 3D de los vóxeles más importantes (CLP), utilizando PySurfer [22]. En azul se representan los núcleos basales, caudado y putamen. En rojo se representan las CLP.

## V. CONCLUSIÓN

Este artículo presenta un sistema de apoyo a la decisión mediante modelos de clasificación ordinal de pacientes de párkinson a partir de imágenes DaTSCAN. Para su desarrollo, se han empleado técnicas de aprendizaje automático, que incluye RL ordinal, y técnicas de normalización espacial y de recuperación de información. El modelo matemático computacional se considera más adecuado para el campo de la biomedicina dada su alta interpretabilidad.

Los resultados avalan que la metodología que utilizamos, empleando todos los vóxeles para la clasificación (junto con regularización en el modelo), obtiene un mejor rendimiento en la clasificación que si solamente se empleasen los vóxeles de las regiones de interés (núcleos basales) o si se emplease un selector de características nominal (ReliefF).

Respecto a la representación en 3D de las CLP, se confirma que los núcleos basales tienen una gran importancia en la tarea de clasificación de un paciente. Pero también se destacan otras zonas corticales que deberían de tenerse en cuenta para futuros estudios en la evaluación de la enfermedad de Parkinson. La densidad de transportadores presinápticos de dopamina tiene una gran importancia en la tarea de clasificación de un paciente, pero habría que tener en cuenta para futuros estudios otras zonas corticales que tendrían influencia en el diagnóstico diferencial de la enfermedad de Parkinson.

Como futuros trabajos se plantean realizar modificaciones en el método de selección de características nominal (ReliefF) para adaptarlo a una clasificación ordinal, de modo que la selección de características ayude a reducir la dimensionalidad del problema y mejorar los resultados. También se propone la aplicación de otros clasificadores como Procesos Gaussianos con núcleo lineal que permitan estimar todos los parámetros del modelo y calcular su incertidumbre.

## REFERENCIAS

- [1] R. Simon, D. Greenberg, and M. Aminoff, "Clinical neurology 5th edition," *Clinical Neurology*, 2009.
- [2] J. Booij, J. B. Habraken, P. Bergmans, G. Tissingh *et al.*, "Imaging of dopamine transporters with iodine-123-fp-cit spect in healthy controls and patients with parkinson's disease," *The Journal of Nuclear Medicine*, vol. 39, no. 11, p. 1879, 1998.
- [3] A. Antonini, K. L. Leenders, P. Vontobel, R. P. Maguire, J. Missimer, M. Psylla, and I. Günther, "Complementary pet studies of striatal neuronal function in the differential diagnosis between multiple system atrophy and parkinson's disease." *Brain: a journal of neurology*, vol. 120, no. 12, pp. 2187–2195, 1997.
- [4] J. Darcourt, J. Booij, K. Tatsch, A. Varrone, T. Vander Borght, Ö. L. Kapucu, K. Nägren, F. Nobili, Z. Walker, and K. Van Laere, "Eann procedure guidelines for brain neurotransmission spect using 123i-labelled dopamine transporter ligands, version 2," *Eur J Nucl Med Mol*, vol. 37, no. 2, pp. 443–450, 2010.
- [5] R. Prashanth, S. D. Roy, P. K. Mandal, and S. Ghosh, "Automatic classification and prediction models for early parkinson's disease diagnosis from spect imaging," *Expert Systems with Applications*, vol. 41, no. 7, pp. 3333–3342, 2014.
- [6] A. Rajput, H. Sitte, A. Rajput, M. Fenton, C. Piffl, and O. Hornykiewicz, "Globus pallidus dopamine and parkinson motor subtypes clinical and brain biochemical correlation," *Neurology*, vol. 70, no. 16 Part 2, pp. 1403–1410, 2008.
- [7] F. Pedregosa-Izquierdo, "Feature extraction and supervised learning on fmri: from practice to theory," Ph.D. dissertation, Université Pierre et Marie Curie-Paris VI, 2015.
- [8] M. Robnik-Šikonja and I. Kononenko, "Theoretical and empirical analysis of relieff and rrelieff," *Machine learning*, vol. 53, no. 1-2, pp. 23–69, 2003.
- [9] B. Magnin, L. Mesrob, S. Kinkingnéhun, M. Pélégriani-Issac, O. Colliot, M. Sarazin, B. Dubois, S. Lehéricy, and H. Benali, "Support vector machine-based classification of alzheimer's disease from whole-brain anatomical mri," *Neuroradiology*, vol. 51, no. 2, pp. 73–83, 2009.
- [10] F. Segovia, J. Górriz, J. Ramírez, I. Alvarez, J. Jiménez-Hoyuela, and S. Ortega, "Improved parkinsonism diagnosis using a partial least squares based approach," *Medical physics*, vol. 39, no. 7, pp. 4395–4403, 2012.
- [11] I. Illán, J. Górriz, J. Ramírez, F. Segovia, J. Jiménez-Hoyuela, and S. Ortega Lozano, "Automatic assistance to parkinson's disease diagnosis in datscan spect imaging," *Medical physics*, vol. 39, no. 10, pp. 5971–5980, 2012.
- [12] A. Winogrodzka, P. Bergmans, J. Booij, E. Van Royen, A. Janssen, and E. C. Wolters, "[123 i] fp-cit spect is a useful method to monitor the rate of dopaminergic degeneration in early-stage parkinson's disease," *Journal of neural transmission*, vol. 108, no. 8, pp. 1011–1019, 2001.
- [13] A. V. García, J. C. Vaamonde, V. G. Poblete, S. M. Rodado, M. R. Cortés, S. S. Ruiz, R. A. Ibáñez, and A. C. Soriano, "Utility of dopamine transporter imaging (123-i ioflupane spect) in the assessment of movement disorders," *Revista española de medicina nuclear*, vol. 23, no. 4, pp. 245–252, 2004.
- [14] G. Perlaki, S. Szekeres, G. Orsi, L. Papp, B. Suha, S. A. Nagy, T. Doczi, J. Janszky, K. Zambo, and N. Kovacs, "Validation of an automated morphological mri-based 123i-fp-cit spect evaluation method," *Parkinsonism & related disorders*, vol. 29, pp. 24–29, 2016.
- [15] F. Segovia, I. Á. Illán, D. Salas-Gonzalez, F. J. Martínez-Murcia, C. Phillips, C. G. Puntonet, J. R. P. de Inestrosa, and J. M. G. Sáez, "Petra: Multivariate analyses for neuroimaging data." in *IWBBIO*, 2014, pp. 1302–1312.
- [16] W. D. Penny, K. J. Friston, J. T. Ashburner, S. J. Kiebel, and T. E. Nichols, *Statistical parametric mapping: the analysis of functional brain images*. Academic press, 2011.
- [17] P. McCullagh, "Generalized linear models," *European Journal of Operational Research*, vol. 16, no. 3, pp. 285–292, 1984.
- [18] P. A. Gutiérrez, M. Pérez-Ortiz, J. Sánchez-Monedero, F. Fernández-Navarro, and C. Hervás-Martínez, "Ordinal regression methods: survey and experimental study," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 1, pp. 127–146, 2016.
- [19] P. A. Gutiérrez, P. Tiño, and C. Hervás-Martínez, "Ordinal regression neural networks based on concentric hyperspheres," *Neural Networks*, vol. 59, pp. 51–60, 2014.
- [20] J. D. Rennie and N. Srebro, "Loss functions for preference levels: Regression with discrete ordered labels," in *Proceedings of the IJCAI multidisciplinary workshop on advances in preference handling*. Kluwer Norwell, MA, 2005, pp. 180–186.
- [21] M. Cruz-Ramírez, C. Hervás-Martínez, J. Sánchez-Monedero, and P. A. Gutiérrez, "Metrics to guide a multi-objective evolutionary algorithm for ordinal classification," *Neurocomputing*, vol. 135, pp. 21–31, 2014.
- [22] Waskom, Gramfort, Burns, Luessi, and Larson, "Pysurfer," 2017. [Online]. Available: <http://pysurfer.github.io>



# Metodología Basada en Agrupamiento y Visualización para el Fenotipado de Pacientes

J. M. Juárez, A. Lopez Martinez-Carrasco, M. Campos, A. Morales

*Facultad de Informática*

*Universidad de Murcia*

{jmjuarez|antonio.lopez31|manuelcampos|morales}@um.es

Francisco Palacios

*Unidad de Cuidados Intensivos*

*Hosp. Universitario de Getafe*

franciscopaula@gmail.com

**Resumen**—El cuidado y tratamiento de pacientes hospitalarios depende en parte de la epidemiología local. La caracterización de grupos de población (fenotipado) a partir de la historia clínica es por tanto una tarea esencial que puede ser tratada con técnicas de aprendizaje computacional. A pesar del gran abanico de técnicas para identificación de grupos, los equipos asistenciales demandan la interpretabilidad de los procesos con el fin de darles una validez médica. En este trabajo proponemos una metodología que desarrolle este proceso de aprendizaje basada en agrupamiento y visualización con el fin de atender a los aspectos de reproducibilidad e interpretabilidad para el clínico. Finalmente demostramos la utilidad de la metodología con un caso de estudio en el campo de la resistencia antibiótica.

**Palabras clave:**—Agrupamiento; Visualización; Subgrupos; Infecciones; Inteligencia Artificial Medicina

## I. INTRODUCCIÓN

La caracterización de los conjuntos poblacionales en el ámbito de la salud es esencial para la mejora de la calidad asistencial. Así, en el ámbito hospitalario, la epidemiología local juega un papel esencial a la hora de tomar decisiones terapéuticas. Por ejemplo, para el problema de la resistencia a la antibioticoterapia, es clave contar con sistemas para la ayuda a la identificación del fenotipo (características físicas y conductuales) de pacientes con una mayor pérdida de efectividad [1], [2].

Desde un punto de vista computacional, este tipo de problemas se traduce en la búsqueda de individuos con una serie de características comunes y formando conjuntos no disjuntos, es decir, un problema de búsqueda de subgrupos. El descubrimiento de subgrupos se define como un método descriptivo y exploratorio de minería de datos [3]. Hay un creciente interés por esta disciplina, proponiéndose un buen conjunto de algoritmos principalmente para datos cualitativos y binarios, realizando una búsqueda exhaustiva o aplicando heurísticas [4], [5]. Existen algunos antecedentes del uso de estas técnicas en el ámbito de la medicina. Por ejemplo, la librería VIKAMINE específica para descubrimiento de subgrupos se ha utilizado para la mejora en el diagnóstico con ultrasonidos [6]. Sin embargo, la búsqueda de grupos de interés suele medirse como la distribución inusual de cierta propiedad de interés, definiendo medidas de calidad de subgrupos. Estas medidas no son triviales y son altamente sensibles al problema específico y a los subgrupos seleccionados.

En el ámbito de la investigación médica existe cierta experiencia en el uso de técnicas de aprendizaje computacional. Por ejemplo, en problemas de clasificación, los algoritmos de árboles de decisión son bien conocidos, puesto que el modelo resultante es aplicable para toma de decisiones, es visual y se fundamenta en la partición de un conjunto de datos. Otras técnicas familiares al médico y que son potencialmente útiles en problemas de fenotipado son los métodos de agrupamiento (clustering) para clasificación no supervisada.

En la última década, debido a la eclosión de proyectos de data-science y la disponibilidad de paquetes estadísticos y de minería de datos, las soluciones para este tipo de problemas se centran en procesos de caja negra, dando poca opción al clínico a incorporar el conocimiento obtenido [7]–[9]. En oposición a esta aproximación, en los últimos años hay un creciente interés por la estrategia *human-in-the-loop* que consiste en involucrar al usuario en las tareas de selección, modelado y validación con el fin de refinar procesos de minería de datos y mejorar en la generación de conocimiento [7], [10]. En problemas del ámbito de la investigación médica, además, es imprescindible permitir la interpretabilidad del algoritmo, la trazabilidad vinculando el modelo obtenido con los pacientes concretos y la reproducibilidad del experimento para su validación clínica.

Las técnicas de visualización tienen el potencial de ayudar a los expertos a entender los modelos y la configuración de los algoritmos y sus resultados [11]. En concreto, la visualización exhaustiva de posibles resultados cuando hay un ajuste de parámetros aporta un gran ahorro de tiempo y costes. Por ejemplo, en [12], la interpretación visual de datos y patrones ha permitido mejorar el modelo obtenido en la obtención de reglas de asociación temporales en infecciones nosocomiales en una UCI.

Las contribuciones de este trabajo son:

- Una metodología para el fenotipado de pacientes dirigida por los principios de trazabilidad e interpretabilidad (Sección II-B)
- Una propuesta genérica de adaptación de técnicas de agrupamiento para resolver problemas de subgrupos (Sección II-A).
- Estudio de caso de aplicación de los puntos anteriores en el contexto médico real de las resistencias antibióticas (Sección III).

## II. SUBGRUPOS MEDIANTE AGRUPAMIENTO

En esta sección describimos una propuesta para el descubrimiento de subgrupos de pacientes basada en técnicas de aprendizaje computacional. La propuesta se compone de dos aspectos fundamentales (ver Fig. 1). En primer lugar la adaptación de técnicas de agrupamiento, familiares en el ámbito clínico, para resolver el problema de subgrupos de forma automática. Así, la Sec. II-A establece el marco formal de esta adaptación. En segundo lugar se propone una metodología para la obtención de subgrupos basado en la estrategia human-in-the-loop (Sec. II-B) con el fin facilitar posteriores estudios en el campo de la investigación médica. Por este motivo, la propuesta se fundamenta en (i) el principio de trazabilidad, es decir, el modelo resultante debe tener una correspondencia clara con los individuos para su evaluación clínica, y (ii) la interpretabilidad del modelo que permitirá posteriormente aportar información experta.

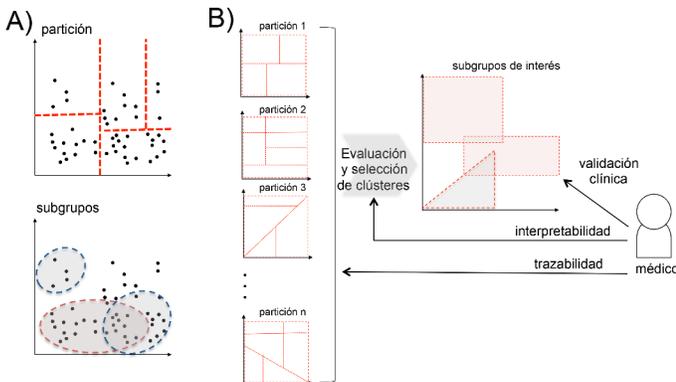


Figura 1. A) De la partición a los subgrupos; B) Trazabilidad, interpretabilidad y validación.

### II-A. Marco formal

A continuación describimos una propuesta de descubrimiento de subgrupos relevantes mediante la utilización de algoritmos de agrupamiento. Esta propuesta parte de la hipótesis de que, tras aplicar los algoritmos de agrupamiento de forma iterada, los conjuntos de individuos que lleguen a permanecer juntos en esos clústeres son los candidatos a conformar los subgrupos que se desean encontrar. Por tanto, la propuesta se fundamentará en la evaluación y comparación de clústeres entre las diferentes particiones obtenidas tras la ejecución de algoritmos de agrupamiento.

Describiremos formalmente los principales elementos de este proceso.

**Def. Partición:** dado un conjunto de datos  $C$ ,  $C_x$  es una partición de  $C$  si  $C_x \subseteq \mathcal{P}(C)$  con  $|C_x| = x$  donde  $C_x = \{C_{x1}, \dots, C_{xx}\}$  y  $C_{x1} \cup \dots \cup C_{xx} = C$ .

**Def. Clúster:** a los elementos de  $C_x$  se les denominan *clústeres*, cumpliendo que  $\forall C_{xi}, C_{xj} \in C_x, C_{xi} \cap C_{xj} = \emptyset$ .

Es decir, denotamos como  $C_{xi}$  y  $C_{xj}$  a dos clústeres de una misma partición  $C_x$ , mientras que  $C_{xi}$  y  $C_{yi}$  son clústeres de que pueden ser de particiones diferentes si  $x \neq y$ .

Denotamos como  $\mathcal{P}(C)_k$  al espacio de particiones de  $C$  con  $k$  clústeres.

**Def. Función Agrupamiento:** dado un conjunto de datos  $C$  y un valor entero positivo  $k$  la función de agrupamiento establece un partición de  $C$  obteniendo  $k$  clústeres.

$$\text{Agrupamiento} : C \times \mathbb{Z}^+ \rightarrow \mathcal{P}(C) \quad (1)$$

Es decir  $\text{Agrupamiento}(C, k) \in \mathcal{P}(C)_k$ .

Por simplicidad en el modelo, y sin pérdida de genericidad, asumimos el uso de algoritmos clásicos de agrupamiento, entendiendo que son aquellos cuyo objetivo es la partición del conjunto de datos en  $k$  subconjuntos (clústeres), siendo este parámetro establecido a-priori.

Un aspecto esencial en el estudio de los algoritmos de agrupamiento es la evaluación de sus particiones mediante índices de validez de los clúster (CVI), como los índices Rand o Silhouette [13], [14]. Entre la evaluación directa de clústeres podemos encontrar diferentes criterios. En [15] se clasifican los CVI como: internos (propiedades de los elementos del clúster), relativos (evaluar la partición en su conjunto según un criterio como el número de individuos) y externos (estructura de la distribución de los individuos). Sin embargo, el método más habitual es definir una función para evaluar un clúster donde destacan métricas de compactación (cercanía entre individuos del clúster) y métricas de separación (separación respecto a individuos del resto de clústeres). En este último grupo, una de las métricas más extendidas es el coeficiente de Jaccard [16], que se define como:

$$J(C_{xi}, C_{yj}) = \frac{|C_{xi} \cap C_{yj}|}{|C_{xi} \cup C_{yj}|} \quad (2)$$

En este trabajo nos centraremos en medidas de evaluación de clústeres de diferentes particiones y con este fin generalizaremos este tipo de métricas a través de la función de coincidencia.

**Def. Función Coincidencia:** dadas dos particiones  $C_x$  y  $C_y$  la métrica de coincidencia entre sus clústeres  $C_{xi}$  y  $C_{yj}$  se define como la función que mide el grado de similitud entre clústeres, normalmente de distinta partición. Formalmente:

$$M : \mathcal{P}(C)_a \times \mathcal{P}(C)_b \rightarrow [0, 1] \quad (3)$$

Cumpliendo las siguientes dos propiedades:

$$M(C_{xi}, C_{yj}) = 1 \iff C_{xi} = C_{yj}. \quad (4)$$

$$M(C_{xi}, C_{yj}) = 0 \iff C_{xi} \cap C_{yj} = \emptyset. \quad (5)$$

En este trabajo, planteamos la idea intuitiva de traza como la tarea de seguimiento de los individuos de un clúster que se encuentran agrupados en los clústeres que otras particiones.

**Def. Función de Traza:** sea un conjunto de datos  $C$  y un conjunto de particiones  $\{C_1, \dots, C_{K-1}\}$  resultante de aplicar iterativamente un algoritmo de agrupamiento donde variamos el número de clústeres ( $1 \dots K$ ). Dado un clúster ( $C_{Ki}$ ) de la partición  $C_K$ , denominamos traza a un conjunto formado por el clúster de cada partición  $C_2, \dots, C_{K-1}$  (descartando  $C_1 = C$ ) que maximiza la función de coincidencia en relación a dicho cluster  $C_{Ki}$ .



$$\text{Traza} : C_K \times \{\mathcal{P}(C)_1, \dots, \mathcal{P}(C)_K\} \rightarrow C_{1i_1} \times \dots \times C_{K-1i_k} \quad (6)$$

En este trabajo presentamos el Algoritmo 1 que implementa dicha función.

---

**Algoritmo 1** Traza
 

---

**Input**  $C_{xi}$ : clúster ;  $\{C_1, \dots, C_x\}$ : conjunto particiones ;  $M$ : función de coincidencia  
**Output**  $T$  %vector de clústeres seleccionados

```

 $T \leftarrow \emptyset$ 
for  $k = x - 1 \dots 2$  do
   $\text{candidato} \leftarrow C_{k1}$ 
  for  $y = 1 \dots k$  do
    if  $M(C_{xi}, C_{ky}) > M(C_{xi}, \text{candidato})$  then
       $\text{candidato} \leftarrow C_{ky}$ 
    end if
  end for
   $T_k \leftarrow \text{candidato}$ 
end for
return  $T$ 

```

---

Siendo  $M$  una función de coincidencia y  $T$  el vector de clústeres seleccionados como traza de  $C_{xi}$ . Cabe destacar que habiendo  $x$  particiones  $(C_1, \dots, C_x)$ ,  $k \in [2, x - 1]$ . Esto es así puesto que: (1)  $C_1$  es una partición con un único clúster y por tanto  $(C_{x,i} \subseteq C_{11})$  y (2)  $C_{xi}$  es un clúster de  $C_x$  y por definición  $C_{xi} \cap C_{xj} = \emptyset$  cuando  $i \neq j$ .

Por ejemplo, sean las particiones  $C_1, \dots, C_5$  decimos que  $\text{Traza}(C_{51}, \{C_1, C_2, C_3, C_4, C_5\}, M) = \langle C_{22}, C_{31}, C_{43} \rangle$  para expresar que, de acuerdo con una métrica de coincidencia  $M$ , gran parte de los individuos del cluster  $C_{51}$  permanecen agrupados en los clústeres  $C_{22}$ ,  $C_{31}$  y  $C_{43}$ .

**Función M-Trazas:** sea un conjunto de datos  $C$  y un valor entero  $K$ , la función  $M - \text{Trazas}$  calcula una matriz de trazas a partir de las particiones de  $C_1 \dots C_K$ , calculando los vectores a través de la función  $\text{Traza}$  para los clústeres de  $C_{Ki}$ .

$$M - \text{Trazas} : C \times Z^+ \rightarrow C_1 \times \dots \times C_{K-1} \quad (7)$$

El Algoritmo 2 presenta una implementación de dicha función. Siguiendo el ejemplo anterior  $M - \text{Trazas}(C, 4) = T$ , donde

---

**Algoritmo 2** M-Trazas: Matriz de Trazas
 

---

**Input**  $C$ : conjunto de datos ;  $K \in Z^+$ ,  $M$ : función de coincidencia  
**Output**  $\mathcal{T}$  %matriz de clústeres seleccionados

```

 $\mathcal{C} = \emptyset$ 
 $\mathcal{T} \leftarrow \emptyset$ 
for  $i = 1 \dots K$  do
   $C_i \leftarrow \text{Agrupamiento}(C, i)$ 
   $\mathcal{C} = \mathcal{C} \cup \{C_i\}$ 
end for
for  $i = 1 \dots K$  do
   $\mathcal{T}_i \leftarrow \text{Traza}(C_{Ki}, \mathcal{C}, M)$ 
end for
return  $\mathcal{T}$ 

```

---

$T$  es una matriz  $4 \times 3$  formado por las filas  $T_1, \dots, T_4$ . Cada fila  $T_i$  es la traza para el clúster  $C_{4i}$

## II-B. Metodología

La metodología para la obtención de subgrupos propuesta está basada en el modelo de trazas de clústeres de la sección

II-A. Esta metodología se resumen en la Fig. 2 y se compone de los siguientes pasos:

1. Extracción de datos y selección de parámetros.
2. Selección de algoritmo y parámetros de agrupamiento.
3. Subgrupos: preselección automática de clústeres.
4. Visualización: asistencia a selección de subgrupos.
5. Validación experta.

El primer paso consiste en la extracción, transformación y carga de las fuentes de datos clínicas. En nuestro caso este proceso se realiza con la herramienta WASPSS [2], que integra datos provenientes de los servicios de microbiología, farmacia, laboratorio y censos de un hospital. Una vez cargados, se procede al diseño de una vista minable, seleccionando los parámetros diana, en función de los objetivos clínicos del estudio. Este conjunto de datos lo denominamos  $C$ .

El segundo paso es la selección del algoritmo de agrupamiento y estimación del número de clústeres máximos esperables, denominados función *Agrupamiento* y parámetro  $K$  respectivamente. Ambas decisiones dependerán de la naturaleza de los parámetros diana seleccionados.

En tercer lugar se pasará al cálculo de clústeres candidatos a ser seleccionados como subgrupos. Con este fin haremos uso de la función  $M - \text{Trazas}$  (Algoritmo 2). Una vez decidido  $C$ ,  $K$  y la función *Agrupamiento* únicamente falta seleccionar una función de coincidencia  $M$  (Expr. 3). En este trabajo proponemos una medida específica basada en el índice de Jaccard (expr. 2), denominada  $J2$  como sigue:

$$J2(C_{xi}, C_{yj}) = \frac{|C_{xi} \cap C_{yj}|}{|C_{yj}|} \quad (8)$$

Esta función está diseñada específicamente para procesos de comparación de un único clúster de poca cardinalidad frente a un conjunto de clústeres previsiblemente de mayor tamaño. Mientras que Jaccard obtiene el ratio entre los elementos comunes frente a todos los elementos,  $J2$  obtiene el ratio frente al segundo clúster, ahorrando el cálculo del denominador. Además,  $J2(a, b)$  respecto a  $J(a, b)$  cumple la siguiente propiedad: si  $|b| < |a| \Rightarrow J2(a, b) > J(a, b)$ . Esta propiedad es útil en nuestro caso, ya que en la búsqueda de subgrupos se deben valorar los subconjuntos de menor cardinalidad que incluyan el mayor número de elementos de nuestro clúster de estudio (en el ejemplo  $a$ ). En resumen, en el tercer paso se calculará la matriz de trazas  $M - \text{Trazas}(C, K, J2) = \mathcal{T}$ .

Una vez hecha la preselección de clústeres, el cuarto paso involucra al experto durante el proceso de elección del modelo computacional. Este paso se implementa mediante técnicas de visualización de los clústeres seleccionados con el fin de que el clínico de forma asistida pueda decidir cuáles son los subgrupos de estudio. En concreto, el objetivo es proporcionar una representación visual de la matriz de trazas  $\mathcal{T}$  conteniendo para cada  $\mathcal{T}_{xi}$  el cluster que más parecido a  $C_{Kx}$  cuando en  $C$  se hace una  $i$ -partición. En particular, el objeto de análisis se centrará en el estudio de cada una de sus filas  $\mathcal{T}_x$  donde se representa la traza del  $C_{Kx}$  para cada tamaño de la partición. Proponemos resumir esta información construyendo

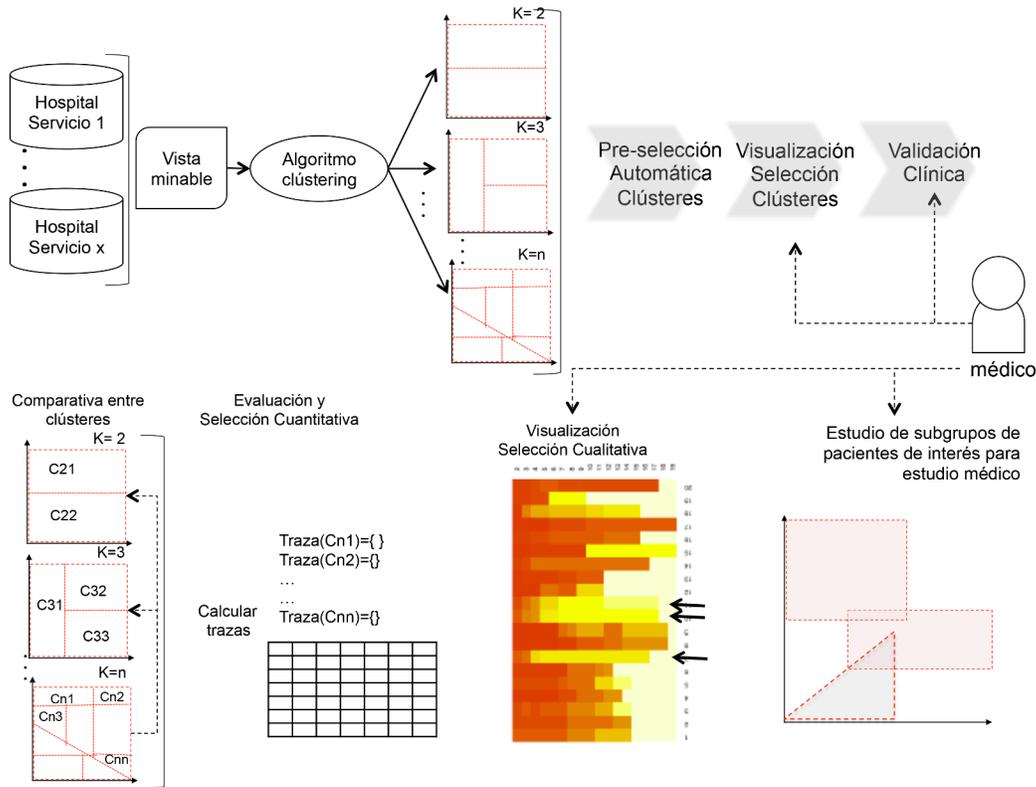


Figura 2. Detalles de la metodología.

la matriz  $\mathcal{J}$  donde  $\mathcal{J}_{xi} = J2(C_{Kx}, \mathcal{T}_{xi})$ , es decir, su grado de coincidencia existente entre  $C_{Kx}$  con  $\mathcal{T}_{xi}$ .

Una vez resumida la información en la matriz  $\mathcal{J}$  se procederá a la representación visual con el objetivo de facilitar la selección de subgrupos. Hay un amplio abanico de técnicas de visualización de datos matriciales, siendo el modelo de *heatmap* una forma efectiva de identificar grupos de valores que destacan por tener valores muy altos o muy bajos utilizando un código de colores. En [17], se demuestra la utilidad del modelo *heatmap* para representación de datos en particiones.

Aunque  $\mathcal{J}_{xi}$  formalmente no cumple ninguna propiedad, en la práctica ocurre con frecuencia que  $\mathcal{J}_{xi} > \mathcal{J}_{xj}$  cuando  $i \ll j$ . Esto sucede ya que la  $i$ -partición tiene menor número de clústeres que la  $j$ -partición y por tanto sus clústeres tendrán en muchos casos una mayor cardinalidad.

En la Figura 2 se muestra un ejemplo de visualización de la matriz  $\mathcal{J}$  donde 3 clústeres de diferentes particiones han sido seleccionados como subgrupos de estudio.

El último paso de esta metodología es la validación de los clústeres seleccionados en el dominio médico. La actividad esencial es el estudio caso a caso de los pacientes incluidos en cada clúster con el fin de analizar la clínica del subgrupo. Al ser esta última etapa principalmente manual y con el fin de obtener resultados objetivos, proponemos adoptar técnicas de validación cuantitativa [18]. En el caso de contar con varios expertos, no gran número debido al dominio, sugerimos las medidas de asociación clásicas propuestas en [19].

### III. EXPERIMENTO

Este experimento se centra en mejorar el problema del uso racional de antibióticos en el hospital. En concreto, el objetivo es identificar grupos de interés entre pacientes con sospecha de infección microbiana y las resistencias antibióticas. En concreto, se estudiará el tratamiento con Vancomicina y el antibiograma de dichos pacientes referente a las bacterias: Staphylococcus Aureus, Enterococcus Faecalis, Staphylococcus Epidermidis, MARSA, Staphylococcus Coagulasa Negativo y Enterococcus Faecium.

En el experimento realizado, se han recopilado datos provenientes de 4 fuentes:

- Historia Clínica: información demográfica: 4 atributos: *pk\_paciente*, *edad*, *sexo*, *tiempo\_ingreso*.
- Dep. Microbiología: cultivos realizados: 6 atributos con información de tiempos de cultivo (ej. *cultivosPrimeras72h* o *cultivosDespues1dia*).
- Dep. Farmacia: información sobre tratamiento antibiótico: 12 atributos booleanos.
- Laboratorio: contexto de flora: 144 atributos (booleanos).

Esta base de datos consta de 169 atributos con un total de 1.778 registros referentes a los cultivos realizados.

La recopilación y almacenamiento de datos se realiza a través de la plataforma WASPSS de vigilancia antimicrobiana [2].

En relación a la limpieza y transformación de datos se han tenido en cuenta las siguientes cuestiones:

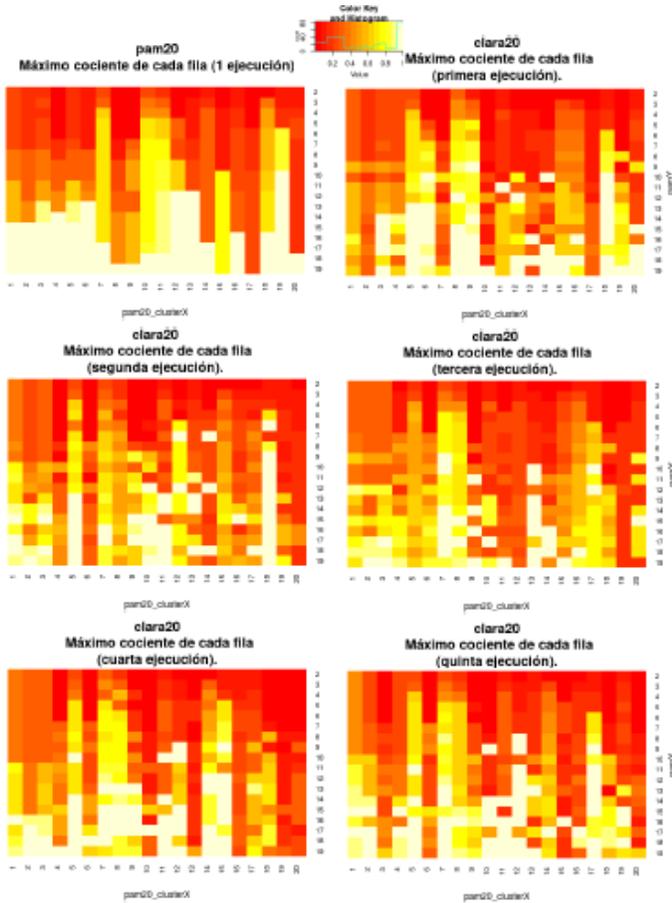


Figura 3. Heatmap de matrices  $\mathcal{J}$ .

- Revisión de filas/columnas duplicadas, atributos vacíos o de valor único.
- Transformación de atributos y creación de características: los datos temporales (fechas) por sugerencia clínica pasan a dos atributos (mes/año) para analizar estacionalidad.
- Dependencia de atributos temporales: ej. *cultivosPrimeras72h* y *cultivosDespues1dia* (booleanos) pasan a 1 único atributo *periodoCultivo* multivaluado ( $< 3, 3 - 10, > 10$ ).
- No se aplican técnicas de reducción dimensional debido a la necesidad de interpretabilidad durante el proceso por parte del médico.

En referente a la discretización de atributos, se han tenido en cuenta métodos de discretización tanto supervisada como no supervisada. Sin embargo, la discretización en datos clínicos tiene un gran impacto en los modelos aprendidos [20] y por tanto se ha guiado por conocimiento médico. Por ejemplo, la edad ha sido discretizada de acuerdo con la clasificación clínica estándar (noenatal, pediátrica, adulta y anciana).

Tras este proceso la vista minable de la base de datos se compone de 1.768 filas y 83 atributos que resumimos en el Cuadro I.

El segundo paso de la metodologías es la selección de algoritmos de agrupamiento y elección de parámetros. En este ex-

Tabla I  
DATOS

Paciente y Antibiograma (4 y 3 atributos)			
Atributo	Contenido	Atributo	Contenido
Sexo	1140/628	Edad	60/27/652/1029
T. Ingreso	2015-2016	Microorg.	[Aureus, ..., Faec]
Susceptib.	Res(21)/Sen(1747)	CMI	[0, 25, ..., 4]
Cultivo (6 atributos)			
Atributo	Contenido	Atributo	Contenido
Tipo	[Sangre, ..., LCR]	Realización	2015-2016
Per.Cultivo	[< 3, 3 - 10, > 10]	Servicio	[UCI, ..., URG]
Contexto Tratamiento (12 atributos)			
Atributo	Contenido	Atributo	Contenido
Vanco_year	yes/no	Vanco_days	yes/no
⋮	⋮	⋮	⋮
Contexto Flora (144 atributos)			
Atributo	Contenido	Atributo	Contenido
MARSA_year	yes/no	Faec_year	yes/no
⋮	⋮	⋮	⋮

perimento hemos seleccionado algoritmos *k-medoids*: PAM y CLARA [21]. Se han elegido algoritmos clásicos al existir antecedentes en la literatura clínica y con el fin de facilitar la interpretación del proceso por parte del médico. De acuerdo con el número total de pacientes y con la epidemiología local, se fijó un número máximo de posibles subgrupos, eligiendo un parámetro  $K = [1, \dots, 20]$ . La función  $M - Trazas$  ha sido desarrollada en R (versión 3.3.2) usando las implementaciones de las funciones de *Agrupamiento* con el paquete *cluster* (versión 2.0.5). En este ejemplo ilustrativo, dado el carácter no determinista del algoritmo CLARA, éste se ha calculado 5 veces mientras que PAM únicamente 1 vez. Esto significa la obtención de un total de 1.254 clústeres, resultantes de analizar 120 clústeres para particiones para  $K = 20$  con 1.134 clústeres para las particiones con  $K = [2, \dots, 19]$ .

Debido al número de clústeres, se han preseleccionado los clústeres  $C_{x,20}$  cuya  $Mean(\sum_2^K \mathcal{J}_{x,i}) > 0,7$  y  $Median(\sum_2^K \mathcal{J}_{x,i}) > 0,7$ . Esta medida adicional ha permitido evitar al experto el estudio manual de gran número de clústeres de total irrelevancia, reduciendo un 92% el número de clústeres a estudiar.

La Fig. 3 muestra el resultado visual de las matrices  $\mathcal{J}$  para su selección por parte del experto. Finalmente, han sido seleccionados para el estudio los clústeres: *pan20\_cluster7*, *pan20\_cluster10*, *pan20\_cluster11*, *pan20\_cluster19*, *clara20\_cluster18* (ejec. 1), *clara20\_cluster7* (ejec. 2), *clara20\_cluster7* (ejec. 3), *clara20\_cluster15* (ejec. 4) y *clara20\_cluster12* (ejec. 5).

Actualmente se están analizando los grupos de pacientes de estos clústeres elegidos para determinar su relevancia clínica.

#### IV. CONCLUSIONES

En este trabajo se aborda el problema de la fenotipado de pacientes para el tratamiento antibiótico. En concreto, se propone una metodología para la búsqueda de subgrupos de individuos con características comunes mediante la adaptación

de algoritmos de agrupamiento y visualización de datos. Se ilustra la utilidad de esta metodología en un caso clínico real.

Desde el punto de vista computacional, la principal contribución es la propuesta de utilización de algoritmos de agrupamiento, donde se evalúan los clústeres para conformar subgrupos. Mientras que existe una gran tradición en el estudio de validez de clústeres mediante CVI [13], [15] para obtener la mejor partición posible, en este trabajo utilizamos dichas técnicas para extraer subgrupos.

Debido a la fuerte componente aplicada al dominio médico, un aspecto esencial de la metodología es la implicación del experto durante todo el proceso [7], [10]. Por tanto, el proceso de obtención de subgrupos debe ser interpretable, utilizando algoritmos que permitan la trazabilidad de los modelos (identificando el paciente original) y apoyado mediante técnicas de visualización.

Hay que indicar que el incremento del número de ejecuciones de los algoritmos de agrupamiento aumenta el número de clúster candidatos a analizar. Esto podría llegar a suponer un cuello de botella para el posterior análisis semiautomático. No obstante el uso de técnicas de visualización y métodos de estadística descriptiva ayudan a descartar un gran número de candidatos. En el experimento descrito en la Sec. III, se computaron 114 particiones obteniendo 1.254 clústeres, pero únicamente los expertos deben revisar un 8% de los mismos.

Entre las líneas de trabajo futura destacamos la exploración y evaluación de técnicas de visualización de trazas y el análisis de otros algoritmos de partición para gestionar el problema del desbalanceo de datos. Desde un punto de vista aplicado, se seguirá desarrollando la metodología propuesta con el fin de identificar nuevos fenotipos en el ámbito de las resistencias antibióticas.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad y fondos FEDER a través del proyecto WASPSS (Ref: TIN2013-45491-R).

#### REFERENCIAS

- [1] F. Palacios, M. Campos, J. Juarez, S. Cosgrove, E. Avdic, B. Canovas-Segura, A. Morales, M. Martinez-Nunez, T. Molina-Garcia, P. Garcia-Hierro, and J. Cacho-Calvo, "A clinical decision support system for an antimicrobial stewardship program," in *HEALTHINF 2016 - 9th International Conference on Health Informatics, Proceedings; Part of 9th International Joint Conference on Biomedical Engineering Systems and Technologies, BIOSTEC 2016*. SciTePress, 2016, pp. 496–501.
- [2] B. Cánovas-Segura, M. Campos, A. Morales, J. M. Juarez, and F. Palacios, "Development of a clinical decision support system for antibiotic management in a hospital environment," *Progress in Artificial Intelligence*, vol. 5, no. 3, pp. 181–197, Aug 2016. [Online]. Available: <https://doi.org/10.1007/s13748-016-0089-x>
- [3] A. Martin, "Subgroup discovery," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 5, no. 1, pp. 35–49, 2015. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1002/widm.1144>
- [4] N. Lavrač, B. Cestnik, D. Gamberger, and P. Flach, "Decision support through subgroup discovery: Three case studies and the lessons learned," *Mach. Learn.*, vol. 57, no. 1-2, pp. 115–143, Oct. 2004. [Online]. Available: <http://dx.doi.org/10.1023/B:MACH.0000035474.48771.cd>

- [5] M. Mampaey, S. Nijssen, A. Feelders, and A. Knobbe, "Efficient algorithms for finding richer subgroup descriptions in numeric and nominal data," in *2012 IEEE 12th International Conference on Data Mining*, Dec 2012, pp. 499–508.
- [6] M. Atzmueller, "Profiling examiners using intelligent subgroup mining," in *In Proc. 10th Intl. Workshop on Intelligent Data Analysis in Medicine and Pharmacology (IDAMAP-2005)*, 2005, pp. 46–51.
- [7] J. Lu, W. Chen, Y. Ma, J. Ke, Z. Li, F. Zhang, and R. Maciejewski, "Recent progress and trends in predictive visual analytics," *Frontiers of Computer Science*, vol. 11, no. 2, pp. 192–207, Apr 2017. [Online]. Available: <https://doi.org/10.1007/s11704-016-6028-y>
- [8] T. Mühlbacher, H. Piringer, S. Gratzl, M. Sedlmair, and M. Streit, "Opening the black box: Strategies for increased user involvement in existing algorithm implementations," *IEEE Transactions on Visualization and Computer Graphics*, vol. 20, no. 12, pp. 1643–1652, 2014.
- [9] J. Krause, A. Perer, and E. Bertini, "Using visual analytics to interpret predictive machine learning models," *arXiv*, vol. abs/1606.05685, 2016. [Online]. Available: <http://arxiv.org/abs/1606.05685>
- [10] P. Tamagnini, J. Krause, A. Dasgupta, and E. Bertini, "Interpreting black-box classifiers using instance-level visual explanations," in *Proceedings of the 2Nd Workshop on Human-In-the-Loop Data Analytics*, ser. HILDA'17. New York, NY, USA: ACM, 2017, pp. 6:1–6:6.
- [11] T. von Landesberger, D. W. Fellner, and R. A. Ruddle, "Visualization system requirements for data processing pipeline design and optimization," *IEEE Transactions on Visualization and Computer Graphics*, vol. 23, no. 8, pp. 2028–2041, Aug 2017.
- [12] H. Ltfi, E. Benmohamed, C. Kolski, and M. B. Ayed, "Enhanced visual data mining process for dynamic decision-making," *Knowledge-Based Systems*, vol. 112, pp. 166 – 181, 2016. [Online]. Available: <https://doi.org/10.1016/j.knsys.2016.09.009>
- [13] Y. Lei, J. C. Bezdek, S. Romano, N. X. Vinh, J. Chan, and J. Bailey, "Ground truth bias in external cluster validity indices," *Pattern Recognition*, vol. 65, pp. 58 – 70, 2017.
- [14] B. Kim, H. Lee, and P. Kang, "Integrating cluster validity indices based on data envelopment analysis," *Applied Soft Computing*, vol. 64, pp. 94 – 108, 2018.
- [15] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed. The address: Academic Press, 2008.
- [16] M. Halkidi, Y. Batistakis, and M. Vazirgiannis, "On clustering validation techniques," *Journal of Intelligent Information Systems*, vol. 17, no. 2, pp. 107–145, Dec 2001.
- [17] T. Mühlbacher and H. Piringer, "A partition-based framework for building and validating regression models," *IEEE Transactions on Visualization and Computer Graphics*, vol. 19, no. 12, pp. 1962–1971, Dec 2013.
- [18] E. Mosqueira-Rey and V. Moret-Bonillo, "Validation of intelligent systems: a critical study and a tool," *Expert Systems with Applications*, vol. 18, no. 1, pp. 1 – 16, 2000. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417499000457>
- [19] M. Kendall and J. Gibbons, *Correlation Methods*, 5th ed. Oxford University Press, 1990.
- [20] I. J. Casanova, M. Campos, J. M. Juarez, A. Fernandez-Fernandez-Arroyo, and J. A. Lorente, "Impact of time series discretization on intensive care burn unit survival classification," *Progress in Artificial Intelligence*, vol. 7, no. 1, pp. 41–53, Mar 2018. [Online]. Available: <https://doi.org/10.1007/s13748-017-0130-8>
- [21] X. Jin and J. Han, *K-Medoids Clustering*. Boston, MA: Springer US, 2017, pp. 697–700. [Online]. Available: [https://doi.org/10.1007/978-1-4899-7687-1\\_432](https://doi.org/10.1007/978-1-4899-7687-1_432)



# A boundary-point approach applied to gene selection in gene expression data

Juan Ramos  
*IBSAL/BISITE Research Group*  
*University of Salamanca*  
 Salamanca, Spain  
 juanrg@usal.es

José A. Castellanos-Garzón  
*IBSAL/BISITE Research Group*  
*University of Salamanca*  
 Salamanca, Spain  
 jantonio@usal.es

Juan F. de Paz  
*IBSAL/BISITE Research Group*  
*University of Salamanca*  
 Salamanca, Spain  
 fcofds@usal.es

Juan M. Corchado  
*BISITE Research Group*  
*University of Salamanca, Osaka Institute of Technology*  
 Salamanca, Spain  
 corchado@usal.es

**Abstract**—In recent years there has been an increasing interest in using hybrid-technique sets to face the problem of meaningful gene selection; nevertheless, this issue remains a challenge. In work *A data mining framework based on boundary-points for gene selection from DNA-microarrays: Pancreatic Ductal Adenocarcinoma as a case study*, we propose a novel hybrid framework based on data mining techniques applied to the problem of meaningful gene selection and the search for new biomarkers. For this purpose, the framework deals with approaches such as statistical significance tests, cluster analysis, evolutionary computation, visual analytics and boundary points. The latter is the core technique of the proposal, which allows us to define two alternative methods of gene selection. Moreover, the framework has added a variable to the study (as the age), which is studied with respect to gene expression levels.

**Index Terms**—Feature selection, Gene selection, Data mining, Cluster analysis, Genetic algorithm, Boundary point. DNA-microarray.

## I. INTRODUCTION

While significant efforts have been placed in the development of new methods and strategies to discover informative genes, the problem remains a challenge today since there is not a single technique able to solve all the underlying issues and adapt to different situations and problems.

We have used hybrid techniques to build a data mining framework for gene selection tasks, because they provide more robust and stable solutions than simple methods [1]–[3]. Generally, simple methods of gene selection assume that some criterion should be met in data, which does not have to be true for all data types. Hence, hybrid techniques fusion different simple methods to reach solutions holding more than one criterion, making solutions more stable with respect to

The research of Juan Ramos González has been co-financed by the European Social Fund and Junta de Castilla y León (Operational Programme 2014-2020 for Castilla y León, BOCYL EDU/602/2016). This work has also been supported by project MOVIURBAN: Máquina social para la gestión sostenible de ciudades inteligentes: movilidad urbana, datos abiertos, sensores móviles. SA070U 16. Project cofinanced with Junta Castilla y León, Consejería de Educación and FEDER funds.

variations in data. On the other hand, hybrid techniques are more flexible to changes in user needs and allow us to replace the methods taking place in the overall proposal without carrying out meaningful changes. Finally, we want to stress that this research has been published in [4].

## II. HYBRID FRAMEWORK

Since HybridFrame is based on data mining techniques, we have focused our efforts on the combination of areas such as evolutionary computation, visual analytics, and cluster analysis, among others to develop a methodology to follow in the domain of gene expression data, Figure 1.

**Statistical filtering module (SFM)** This module is responsible for a preliminary data processing and the first gene filtering processes based on statistical significance. Thus, the first process in this module consists of a data treatment by removing control probes, standardizing, and applying algorithms of missing data treatment if needed.

The first applied filter method is the Mann-Whitney test [5]. Then a second filter method is selected in relation to user goals. In this case, the module implemented five filter methods, although new methods can be added. In our case study we used Kruskal-Wallis, which can be used by when introducing a variable measurement external to the dataset to filter out genes related to the variable of interest.

**Hierarchical clustering method module (HCMM)** The dataset resulting from the module above is divided into subsets (clusters) in order to move the complex gene selection task from the whole current dataset to smaller gene subsets. The idea consists of applying data clustering methods to divide the complex task of gene selection from a big dataset into small subsets (divide and conquer strategy), identified by their gene similarity. Although this module does not really perform a gene filtering task, it partitions the data for the following stages.

**Visual analytics module (VAM)** This module selects the most suitable clustering from each input dendrogram. Internal

measures of cluster validity (such as homogeneity, separation and silhouette width) are applied to input dendrograms to estimate level ranges with high quality clusterings. [6], [7], which are applied to each level of a dendrogram to select the one with the best score. Then consists of choosing and visually validating a level from each level interval computed in the process above. For this propose, each dendrogram is explored from its level interval through a linked visualization set, supporting heatmaps, dendrograms, parallel coordinates, 3D-scatterplots and boundary gene visualizations.

**Clustering boundary module (CBM)** This module carries out a filtering process by extracting out the boundary genes for each cluster given from input clusterings to the module. The boundary point algorithm used for this purpose is focused on the ClusterBoundary algorithm given in [8].

The final stage of the framework consists in two alternative selection methods:

- **Clustering intersection method (CIM):** the CIM method is based on the idea of boundary intersections coming from different clustering methods. We assume that boundary genes achieved from the intersection of different clustering boundaries coming from different methods, which develop different cluster strategies on data, are the main candidates to be informative genes.
- **Evolutionary hierarchical clustering method (ECM):** The second method leading to discover informative genes in this framework is ECM, as shown in Fig 1. This method is based on the evolutionary model for clustering (EMHC) given in [9], [10]. We propose that, since dendrograms given as ECM solutions inherit, alter, recombine and even improve part of the genetic code (high quality clusters) of good solutions given by others methods, then it is expected that genes located on the boundary of such clusters are strong candidates to be informative genes.

### III. CASE STUDY ON PANCREATIC DUCTAL ADENOCARCINOMA

As a case study to apply and validate our proposal, we have focused our attention on the tissue sample study of pancreatic ductal adenocarcinoma (PDAC) through microarray technology, given that PDAC has been identified as one of the most aggressive types of existing cancer [11], [12]. Although every cancer has a strong relation to age due to several cellular processes, but for PDAC, this relation appears to be more remarkable than other cancers. In fact, 85% of pancreatic cancer cases involve patients older than 65-years old with a diagnosis mean age of 73-years old [13]. For that reason, this research introduces the age factor for further analysis of its influence in cancer patients.

After applying the methodology above, two sets of genes were obtained, one for each filter method, identifying informative genes of each method. Information about each concrete gene has previously been identified in other research and/or databases as a PDAC related gene. Information provided by both tables was consulted in PED

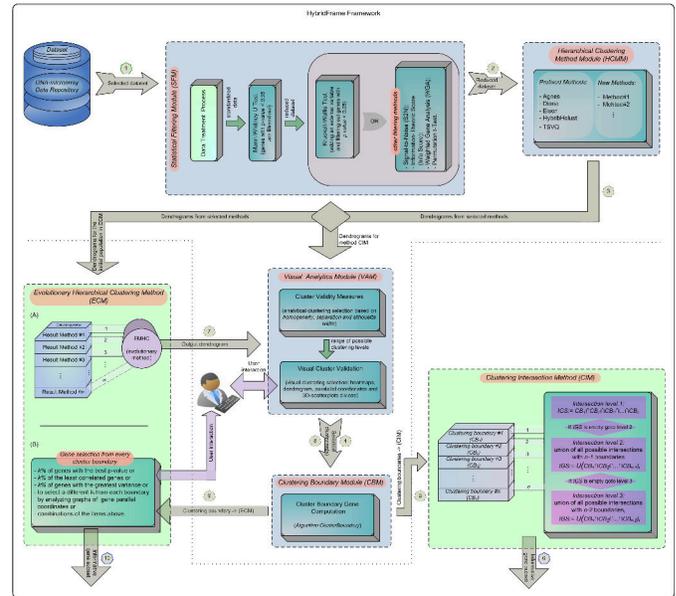


Fig. 1. Chart representing the data mining framework HybridFrame for gene selection.

(<http://www.pancreasexpression.org/>) and Pancreatic Cancer Database (<http://pancreaticcancerdatabase.org/index.php>). Selected genes have a larger relation to normal and tumor tissue samples of PDAC and are highly age-related. Moreover, 10 genes from these tables were identified by both methods (genes in the intersection are highlighted in both tables), meaning they could be even more meaningful for PDAC than the rest. In summary, according to the whole discovery process of informative genes given by Hybridframe, we assume that selected genes can be considered for further pharmaceutical research.

### ACKNOWLEDGMENT

We would like to thank Dr. Liviu Badea from Bioinformatics research group, National Institute for Research in Informatics (Romania) for provided additional information on the dataset used in this research.

### REFERENCES

- [1] I. Guyon, "An introduction to variable and feature selection," *Journal of Machine Learning Research*, vol. 3, pp. 1157–1182, 2003.
- [2] J. Jager, R. Sengupta, and W. Ruzzo, "Improved gene selection for classification of microarrays," in *Pacific Symposium on Biocomputing (UW CSE Computational Biology Group)*, PMID: 12603017, 2003.
- [3] C. Lazar, J. Taminau, D. Meganck, S. and Steenhoff, A. Coletta, V. Molter, C. and deSchaezen, H. Duque, R. and Bersini, and A. Nowé, "A survey on filter techniques for feature selection in gene expression microarray analysis," *IEEE/ACM Transactions On Computational Biology And Bioinformatics*, vol. 9, no. 4, pp. 1106–1118, 2012.
- [4] J. Ramos, J. A. Castellanos-Garzón, J. F. de Paz, and J. Corchado, "A data mining framework based on boundary-points for gene selection from DNA-microarrays: Pancreatic Ductal Adenocarcinoma as a case study," *Engineering Applications of Artificial Intelligence, Elsevier*, vol. 70, pp. 92–108, 2018.
- [5] P. Weiss, "Applications of generating functions in nonparametric tests," *The Mathematica Journal*, vol. 9, no. 4, pp. 803–823, 2005.



- [6] D. Jiang, C. Tang, and A. Zhang, "Cluster analysis for gene expression data: A survey," *IEEE Transactions on Knowledge and Data Engineering*, vol. 16, no. 11, pp. 1370–1386, 2004.
- [7] L. Kaufman and P. J. Rousseeuw, *Finding Groups in Data. An Introduction to Clustering Analysis*. John Wiley & Sons, Inc., Hoboken, New Jersey, 2005.
- [8] J. Castellanos-Garzón, C. García, P. Novais, and F. Díaz, "A visual analytics framework for cluster analysis of DNA microarray data," *Expert Systems with Applications, Elsevier*, vol. 40, pp. 758–774, 2013.
- [9] J. Castellanos-Garzón, "Evolutionary framework for DNA microarray cluster analysis," Ph.D. dissertation, Department of Computer Science, University School of Computer Science, University of Valladolid, 2012.
- [10] J. A. Castellanos-Garzón and F. Díaz, "An evolutionary computational model applied to cluster analysis of DNA microarray data," *Expert Systems with Applications, Elsevier*, vol. 40, pp. 2575–2591, 2013.
- [11] L. Badea, V. Herlea, S. Olimpia, T. Dumitrascu, and I. Popescu, *Combined Analysis of Whole-Tissue and Microdissected PDAC*, Bioinformatics group, National Institute for Research in Informatics, Bucharest 011455, Romania, 2008.
- [12] —, "Combined gene expression analysis of whole-tissue and microdissected pancreatic ductal adenocarcinoma identifies genes specifically overexpressed in tumor epithelia," *Hepato-Gastroenterology*, vol. 88, pp. 2015–2026, 2008.
- [13] J. Koorstra, S. Hustinx, G. Offerhaus, and A. Maitra, "Pancreatic carcinogenesis," *Pancreatology*, vol. 8, no. 2, pp. 110–125, 2008.



**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ANTONIO GONZÁLEZ  
ENRIQUE HERRERA-VIEDMA

**Secretaría Técnica:**

RAUL PÉREZ Y JAVIER CABRERIZO





**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

**ESTYLF1: SESIÓN ESPECIAL:  
FUNCIONES DE AGREGACIÓN  
Y CONECTIVOS LÓGICOS**

**Organizadores:**

SEBASTIA MASSANET, JUAN VICENTE RIERA,  
DANIEL RUIZ-AGUILERA, JOAN TORRENS







# Complexity of Increasing $\phi$ -Recursive Computable Aggregations

Ramón González-del-Campo

Faculty of Informatics, Complutense University of Madrid  
Email: rgonzale@ucm.es

Luis Garmendia

Faculty of Informatics, Complutense University of Madrid  
Email: lgarmend@fdi.ucm.es

Javier Montero

Faculty of Mathematics, Complutense University of Madrid  
Email: monty@mat.ucm.es

**Abstract**—In this paper the new concepts of  $\mathcal{O}(f(n))$ -increasing  $\phi$ -recursive and  $\mathcal{O}(f(n))$ -decreasing  $\psi$ -recursive computable aggregation and expansion function are proposed to describe the computational cost of recursive computational aggregations when the universe of the discourse is increased or decreased are related. The complexity costs of the expansion functions with the complexity costs of its recursive computational aggregations.

## I. INTRODUCTION

As stressed in [11], much effort is needed in analyzing the properties of the algorithms we apply to solve aggregation problems in practice. In fact, in [11], the authors pointed out that it is the available algorithm what defines each aggregation, making feasible a specific solution to each possible problem, of course depending on decision maker's tools and capacities. Such computable aggregations come with a protocol that enables us to face aggregation problems in a specific general framework. For example, when the cardinal of data is not being fixed, or cannot be a priori fixed. In particular, recursive aggregations [4], [5], [6], [7], [9] are a special kind of computable aggregations that play a strong role when the universe is modified. The computational cost is critical when it is necessary to process a huge amount of data.

When recursive aggregations are used it is necessary to know the cost to recompute the new value of the aggregation if the universe is changed adding or removing data. In this paper, two new concepts are proposed to describe the computational cost of recursive computational aggregations when the universe of the discourse is modified by adding or removing an element. On the one hand, the  $\mathcal{O}(f(n))$ -increasing  $\phi$ -recursive computable aggregations is a set of recursive computable aggregations that have a computational cost bounded by  $f(n)$  when an element is added to the universe. The expansion function of a computable recursive aggregation allows to know its computational cost. On the other hand, the  $\mathcal{O}(f(n))$ -decreasing  $\psi$ -recursive computable aggregations are defined in similar way when an element is removed from the universe.

## II. PRELIMINARIES

The concept of computational complexity cost of an algorithm is an important consideration in computer sciences as

a degree to measure the quality and usability of programs. It can be measured in terms of time or memory usage, but it is usually measured in terms of number of operations, and how this number grows as the size of data grows comparing with a function or order in which adding constants, multipliers or lower order functions do not affect the main kind of growing of the higher order.

**Definition 1.** [3] Let  $f : \mathbb{N} \rightarrow \mathbb{R}$  be a function. The set of functions in the order of  $f$ ,  $\mathcal{O}(f)$ , are defined as follows:

$$\mathcal{O}(f) \equiv \{g : \mathbb{N} \rightarrow \mathbb{R} \mid \exists c \in \mathbb{R}, n_0 \in \mathbb{N} \forall n \geq n_0 \\ g(n) \leq cf(n)\}$$

The order of  $f$  contains all the functions that grows up slower than  $f$ .

**Definition 2.** [3] Let  $f : \mathbb{N} \rightarrow \mathbb{R}$  be a function. The computational complexity of  $f$ ,  $\Theta(f)$ , is defined as follows:

$$\Theta(f) \equiv \{g : \mathbb{N} \rightarrow \mathbb{R} \mid \exists c, d \in \mathbb{R}, n_0 \in \mathbb{N} \forall n \geq n_0 \\ df(n) \leq g(n) \leq cf(n)\}$$

**Definition 3.** [3] Let  $f, g : \mathbb{N} \rightarrow \mathbb{R}$  be two functions. It is said  $f$  has a complexity lower than  $g$  if  $\mathcal{O}(f) \subset \mathcal{O}(g)$

**Proposition 1.** [3] Let  $q, a$  be two real numbers such that  $q > 1$  and  $a > 1$ . Then:

$$\mathcal{O}(1) \subset \mathcal{O}(\log(n)) \subset \mathcal{O}(n) \subset \mathcal{O}(n^q) \subset \mathcal{O}(a^n) \subset \mathcal{O}(n!)$$

In the following definition the most usual types of complexity are introduced.

**Definition 4.** [3] Let  $g : \mathbb{N} \rightarrow \mathbb{R}^+$  be a function. Then:

- $g$  has constant complexity if  $g$  belongs to  $\Theta(1)$ , i.e, if  $g$  grows up as fast as  $f(n) = 1$ .
- $g$  has logarithmic complexity if  $g$  belongs to  $\Theta(\log(n))$ , i.e, if  $g$  grows up as fast as  $f(n) = \log(n)$ .
- $g$  has linear complexity if  $g$  belongs to  $\Theta(n)$ , i.e, if  $g$  grows up as fast as  $f(n) = n$ .
- $g$  has polynomial complexity if  $g$  belongs to  $\Theta(n^q)$  for some  $q > 1$ , i.e, if  $g$  grows up as fast as  $f(n) = n^q$ .
- $g$  has exponential complexity if  $g$  belongs to  $\Theta(a^n)$  for some  $a > 1$ , i.e, if  $g$  grows up as fast as  $f(n) = a^n$ .

- $g$  has factorial complexity if  $g$  belongs to  $\Theta(n!)$ , i.e, if  $g$  grows up as fast as  $f(n) = n!$ .

**Definition 5.** [3] *The computational complexity cost of an algorithm is the order of the function that gives the computing time of the algorithm.*

It is possible a definition of computational complexity cost focusing on the number of operations to complete the algorithm:

**Definition 6.** [3] *The computational complexity cost of an algorithm is the order of the function that gives a bound for the number of operations of the algorithm.*

**Definition 7.** [1] *A  $L$  list is an Abstract Data Type (ADT) that represents a sequence of values. A list can be defined by its behavior and its implementation must provide at least the following operations:*

- Test whether a list is empty or not.
- Add a value.
- Remove a value.
- Compute the length (number of values) of a list.

A list can be defined under a template data. For example, a list  $L < [0, 1] >$  is a list of values in  $[0, 1]$ .

Talking about complexity of algorithms implies to show the code of them. There are a lot of programming languages (C++, Python, Java,...). Python is a easy to understand programming language. Even if you do not know Python, you can understand a program written in Python. That is the reason why the programs are written in Python in this paper. All programs here showed can be rewritten in any other programming language.

**Definition 8.** [5] *A left-recursive connective rule is a family of connective operators:*

$$(Ag : [0, 1]^n \rightarrow [0, 1])_{n>1}$$

such that there exists a sequence of binary operators:

$$(L_n : [0, 1]^2 \rightarrow [0, 1])_{n>1}$$

verifying:

- $Ag(a_1, a_2) = L_2(a_1, a_2)$
- $Ag(a_1, \dots, a_n) = L_n(Ag(a_1, \dots, a_{n-1}), a_n)$  for all  $n > 2$

for some ordering rule  $\pi$ .

In similar way a right-recursive connective rule can be defined.

A right-recursive connective and left-recursive connective rule is called recursive connective rule.

**Definition 9.** [2] *An aggregation operator is a mapping  $Ag : [0, 1]^n \rightarrow [0, 1]$  that satisfies:*

- 1)  $Ag(0, 0, \dots, 0) = 0$  and  $Ag(1, 1, \dots, 1) = 1$ .
- 2)  $Ag$  is monotonic.

There exists some other proposals to fusion information as the pre-aggregation functions that introduce the concept

of directional monotonicity and have been useful in some applications.

**Definition 10.** [10] *A mapping  $F : [0, 1]^n \rightarrow [0, 1]$  is a  $n$ -dimensional pre-aggregation function if it satisfies:*

- There exists a real vector  $r \in [0, 1]^n$  with  $r \neq 0$  such that is  $r$ -growing.
- $F(0, \dots, 0) = 0$  and  $F(1, \dots, 1) = 1$ .

Next definition shows a wider point of view about aggregation. It is possible to extend the domain of aggregations to lists of elements  $L$  with generic types  $T$ . For example,  $T$  can be an image and the aggregation that process it can make the fusion of images.

In this paper of article, we will focus on the aggregations that can be computed using a program and the cost of computation of these aggregations.

**Definition 11.** [11] *Let  $L < T >$  be a list of  $n$  elements of type  $T$ . A computable aggregation  $Ag_c$  is a program  $P$  that transforms the list  $L < T >$  into an element of  $T$ .*

**Definition 12.** [8] *Let  $L = \{x_1, \dots, x_n\}$  be a list of values. A computable aggregation rule  $Ag_c$  is recursive if there exists a mapping  $\phi : [0, 1]^2 \rightarrow [0, 1]$  such that:*

$$Ag_c(L) = \begin{cases} x_1, & \text{if } \text{lenght}(L) = 1; \\ \phi(Ag_c(x_1, \dots, x_{n-1}), x_n), & \text{if } \text{lenght}(L) > 1. \end{cases}$$

**Definition 13.** [8] *A computation aggregation rule is expansible if there exists a mapping  $\phi : [0, 1]^2 \rightarrow [0, 1]$  satisfying the following property:*

$$Ag_c(L_1 \cup L_2) = \phi(Ag_c(L_1), Ag_c(L_2))$$

where  $\phi$  is an algorithm with linear or lower computational complexity cost.

Note. Let *Comp*, *Rec* and *Exp* be the computable aggregations, the recursive aggregations and the expansible aggregations respectively. Then:

$$Exp \subset Rec \subset Comp$$

Talking about complexity of algorithms implies to show the code of algorithms that implement them. There are a lot of programming languages (C++, Python, Java,...). Python is a easy to understand programming language. Even if you do not know Python, you can understand a program written in Python. That is the reason why the programs are written in Python in this paper. All programs here showed can be rewritten in any other programming language.

### III. INCREASING $\phi$ -RECURSIVE COMPUTABLE AGGREGATIONS RULES

Let  $L = \{x_1, \dots, x_n\}$  be a list of values and  $n$  its length.

**Definition 14.** *A computable aggregation rule  $Ag_c$  is  $\mathcal{O}(f(n))$ -increasing  $\phi$ -recursive if there exists a mapping  $\phi : [0, 1]^2 \times L \rightarrow [0, 1]$  such that:*

- $Ag_c(L) = \begin{cases} x_1, & \text{if } n = 1; \\ \phi(Ag_c(x_1, \dots, x_{n-1}), x_n, \{x_1, \dots, x_{n-1}\}), & \text{if } n > 1. \end{cases}$
- $\phi$  has a  $\mathcal{O}(f(n))$  complexity cost.



**Definition 15.** A  $\mathcal{O}(f(n))$ -increasing  $\phi$ -recursive computable aggregation rule  $Ag_c$  is non depending of length  $L$  if there exists a mapping  $\phi : [0, 1]^2 \rightarrow [0, 1]$  such that:

- $Ag_c(L) = \begin{cases} x_1, & \text{if } n = 1; \\ \phi(Ag_c(x_1, \dots, x_{n-1}), x_n), & \text{if } n > 1. \end{cases}$
- $\phi$  has a  $\mathcal{O}(f(n))$  complexity cost.

Next lemmas relate types of increasing  $\phi$ -recursive computable aggregations with recursive computable aggregations and expansible computable aggregations given in Definition 12 and Definition 13.

The next two lemmas are trivial:

**Lemma 1.** A recursive computable aggregation is  $\mathcal{O}(f(n))$ -increasing  $\phi$ -recursive for some  $f(n)$ .

**Lemma 2.** If  $Ag_c$  is an expansible computable aggregation, then  $Ag_c$  is a  $\mathcal{O}(n)$ -increasing  $\phi$ -recursive computable aggregation.

The following lemmas show some  $\mathcal{O}(n)$ -increasing  $\phi$ -recursive computable aggregations.

**Lemma 3.** Arithmetic mean is a  $\mathcal{O}(1)$ -increasing  $\phi$ -recursive computable aggregation.

*Proof.*  $Ag_c(x_1, \dots, x_{n+1}) =$   
 $= \frac{1}{n+1} \sum_{i=1}^{n+1} x_i = \frac{1}{n+1} (\sum_{i=1}^n x_i + x_{n+1}) =$   
 $= \frac{n}{n+1} \sum_{i=1}^n x_i + \frac{n}{n+1} x_{n+1} = \frac{n}{n+1} Ag_c(x_1, \dots, x_n) +$   
 $\frac{n}{n+1} x_{n+1}$

So  $\phi(x, y, n) = \frac{n}{n+1}x + \frac{1}{n+1}y$ .

The next two programs compute  $\phi(x, y, \{x_1, \dots, x_n\})$  when  $n$  (length of  $\{x_1, \dots, x_n\}$ ) is known and when  $n$  is not known:

- $n$  is known:

```
def phi(x, y, n):
    return (n*x+y)/(n+1)
```

So  $\phi$  is  $\mathcal{O}(1)$  complexity.

- $n$  is unknown:

```
def phi(x, y, l):
    n=len(l)
    return (n*x+y)/(n+1)
```

Then, it is  $\mathcal{O}(n)$  complexity to compute  $length(l)$ . □

**Lemma 4.** The Product computable aggregation is a  $\mathcal{O}(1)$ -increasing  $\phi$ -recursive computable aggregation.

*Proof.*  $Ag_c(x_1, \dots, x_{n+1}) =$   
 $= \prod_{i=1}^{n+1} x_i = x_{n+1} * \prod_{i=1}^n x_i$

So  $\phi(x, y) = x * y$ , which have a  $\mathcal{O}(1)$  constant complexity cost.

The next program computes  $\phi(x, y)$ :

```
def phi(x, y):
    return x*y
```

So  $\phi$  is  $\mathcal{O}(1)$  complexity. □

**Lemma 5.** Bounded sum ( $\min\{1, \sum_{i=1}^n x_i\}$ ) is a  $\mathcal{O}(1)$ -increasing  $\phi$ -recursive computable aggregations.

*Proof.* There exist three cases:

- 1) If  $Ag_c(x_1, \dots, x_n) = 1$ , then  $Ag_c(x_1, \dots, x_{n+1}) = 1$
- 2) If  $Ag_c(x_1, \dots, x_n) < 1$  and  $Ag_c(x_1, \dots, x_n) + x_{n+1} \geq 1$ , then  $Ag_c(x_1, \dots, x_{n+1}) = 1$
- 3) If  $Ag_c(x_1, \dots, x_n) + x_{n+1} < 1$ , then  $Ag_c(x_1, \dots, x_{n+1}) = Ag_c(x_1, \dots, x_n) + x_{n+1}$

The next program computes  $\phi(x, y)$ :

```
def phi(x, y):
    if x==1:
        res=1
    else:
        if x+y>=1:
            res=1
        else:
            res=x+y
    return res
```

with  $\mathcal{O}(1)$  constant complexity cost. □

**Lemma 6.** Geometric mean is a  $\mathcal{O}(1)$ -increasing  $\phi$ -recursive computable aggregations if  $n$  is known.

*Proof.*  $Ag_c(x_1, \dots, x_{n+1}) =$   
 $= (\prod_{i=1}^{n+1} x_i)^{\frac{1}{n+1}} = (x_n \prod_{i=1}^n x_i)^{\frac{1}{n+1}} =$   
 $(x_n)^{\frac{1}{n+1}} (\prod_{i=1}^n x_i)^{\frac{1}{n+1}} = (x_n)^{\frac{1}{n+1}} ((\prod_{i=1}^n x_i)^{\frac{1}{n}})^{\frac{n}{n+1}}$   
 $= (x_n)^{\frac{1}{n+1}} Ag_c(x_1, \dots, x_n)^{\frac{n}{n+1}}$

So  $\phi(x, y) = x^{\frac{n}{n+1}} * y^{\frac{1}{n+1}}$ .

The two next programs compute  $\phi(x, y, \{x_1, \dots, x_n\})$  depending if  $n$  (length of  $\{x_1, \dots, x_n\}$ ) is known or not:

- $n$  is known:

```
def phi(x, y, n):
    return res x**(n/(n+1))*y**(n/(n+1))
```

So  $\phi$  is  $\mathcal{O}(1)$  complexity.

- $n$  is unknown:

```
def phi(x, y, l):
    n=len(l)
    return res x**(n/(n+1))*y**(n/(n+1))
```

So  $\phi$  is  $\mathcal{O}(n)$  complexity cost. □

**Lemma 7.** The forward and backward aggregations ( $Ag_{cn}^f$  and  $Ag_{cn}^b$ ) over the binary operator  $A$  are  $\mathcal{O}(c(x, y))$ -increasing  $\phi$ -recursive computable aggregations.

*Proof.* Let  $A(x, y)$  be a binary operator and let  $c(x, y)$  be its complexity.

$Ag_{n+1}^f(\{x_1, \dots, x_{n+1}\}) = A(Ag_{cn}^f(\{x_1, \dots, x_n\}, x_{n+1}))$ .

Then  $\phi(x, y) = A(x, y)$  and  $\phi(x, y)$  is computed with  $\mathcal{O}(c(x, y))$ . So  $Ag_{cn}^f$  is a  $\mathcal{O}(c(x, y))$ -increasing  $\phi$ -recursive computable aggregation.

In similar way it is possible to prove  $Ag_{cn}^b$  is a  $\mathcal{O}(c(x, y))$ -increasing  $\phi$ -recursive computable aggregation. □

**Corollary 1.** Minimum, Maximum, Product, Forward and Backward aggregations are non depending of length increasing  $\phi$ -recursive computable aggregations.

Aggregation	$\phi$	Complexity of $\phi$
Arithmetic mean	$\frac{n}{n+1}x + \frac{1}{n+1}y$	$\mathcal{O}(1), \mathcal{O}(n)$
Minimum	$\min\{x, y\}$	$\mathcal{O}(1)$
Maximum	$\max\{x, y\}$	$\mathcal{O}(1)$
Product	$x * y$	$\mathcal{O}(1)$
Bounded sum	See program	$\mathcal{O}(1)$
Geometric mean	$\frac{x}{n^{n+1}} * \frac{y}{n^{n+1}}$	$\mathcal{O}(1), \mathcal{O}(n)$
$Ag_{cn}^f(\{x_1, \dots, x_n\})$	$A(x, y)$	$\mathcal{O}(c(x, y))$
$Ag_{cn}^b(\{x_1, \dots, x_n\})$	$A(x, y)$	$\mathcal{O}(c(x, y))$

TABLE I

EXPANSION FUNCTIONS COMPLEXITY COST OF SOME INCREASING  $\phi$ -RECURSIVE COMPUTABLE AGGREGATIONS.

*Proof.* Trivial.  $\square$

**Lemma 8.** Let  $Ag_c^{\mathcal{O}(f(n)})$  and  $Ag_c^{\mathcal{O}(g(n)})$  be the sets of  $\mathcal{O}(f(n))$ -increasing  $\phi$ -recursive and  $\mathcal{O}(g(n))$ -increasing  $\phi$ -recursive computable aggregations respectively. If  $f(n)$  belongs to  $\mathcal{O}(g(n))$ , then

$$Ag_c^{\mathcal{O}(f(n))} \subseteq Ag_c^{\mathcal{O}(g(n))}$$

*Proof.* Trivial.  $\square$

**Theorem 1.** Let  $\phi$  be the expansion function of  $Ag_c$ . If the complexity of  $\phi$  is  $\Theta(f(n))$  then  $Ag_c$  is approachable with complexity  $\Theta(n * f(n))$ .

*Proof.* Let  $f(n)$  be the function that represents the computing time of  $\phi$ . The next algorithm computes  $Ag_c(x_1, \dots, x_n)$  using  $\phi$ :

```
def phi(y, x):
    ...
def Ag_c(psi, l):
    for x in l:
        aux=phi(aux, x)
    return aux
```

The number of times that the code of the loop `for` is executed depends on the length of list `l`,  $n$ . So  $Ag_c$  takes a computing time  $n * f(n)$ .  $\square$

**Corollary 2.** If  $\phi$  has a polynomial complexity cost, then  $Ag_c$  has a polynomial complexity cost.

*Proof.* If  $\phi$  has a polynomial complexity its computing time is  $f(n) = k * n^a$  for some  $a$ . Then, due to Theorem 1 the computing time for  $Ag_c$  using  $\phi$  is  $k' * n * k * n^a = k'' n^{a+1}$ . So the computing time of  $Ag_c$  belongs to  $\Theta(n^{a+1})$  which is also polynomial complexity cost.  $\square$

#### IV. DECREASING $\psi$ -RECURSIVE COMPUTABLE AGGREGATIONS RULES

Let  $\Omega$  be a region in  $\mathbb{R}^2$  such that  $\Omega \subseteq \mathbb{R}^2$ .

**Definition 16.** Let  $L = \{x_1, \dots, x_n\}$  be a list of values. A computable aggregation rule  $Ag_c$  is  $\mathcal{O}(f(n))$ -decreasing  $\psi$ -recursive in  $\Omega$  if there exists a mapping  $\psi : [0, 1]^2 \rightarrow [0, 1]$  such that:

- For all  $(x, y)$  in  $\Omega$ :  $Ag_c(L \setminus \{x_n\}) = \psi(Ag_c(x_1, \dots, x_n), x_n)$  if  $length(L) > 1$

- $\psi$  has a  $\mathcal{O}(f(n))$  complexity cost.

**Lemma 9.** Arithmetic mean is a  $\mathcal{O}(1)$ -decreasing  $\psi$ -recursive computable aggregation.

*Proof.*  $Ag_c(x_1, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (\sum_{i=1}^{n-1} x_i + x_n) = \frac{1}{n} \sum_{i=1}^{n-1} x_i + \frac{1}{n} * x_n = \frac{n-1}{n} Ag_c(x_1, \dots, x_{n-1}) + \frac{1}{n} * x_n$

So  $Ag_c(x_1, \dots, x_{n-1}) = \frac{n}{n-1} (Ag_c(x_1, \dots, x_n) - \frac{1}{n} x_n)$  and  $\psi(x, y, n) = \frac{n}{n-1} x + \frac{1}{n-1} y$  in  $\Omega = \mathbb{R}^2$ .

The next program compute  $\psi(x, y, \{x_1, \dots, x_n\})$  depending if  $n$  (length of  $\{x_1, \dots, x_n\}$ ) is known or not:

- $n$  is known:

```
def phi(x, y, n):
    return n/(n-1)*x - 1/(n-1)y
```

So  $\psi$  is  $\mathcal{O}(1)$  complexity.

- $n$  is unknown:

```
def phi(x, y, l):
    n=len(l)
    return n/(n-1)*x - 1/(n-1)y
```

So  $\psi$  has  $\mathcal{O}(n)$  complexity for the computation of  $length(L)$ .  $\square$

**Lemma 10.** Minimum and Maximum are  $\mathcal{O}(1)$ -decreasing  $\psi$ -recursive computable aggregations.

*Proof.* If  $\min\{x_1, \dots, x_n\} < x_n$ , then  $\min\{x_1, \dots, x_{n-1}\} = \min\{x_1, \dots, x_n\}$  and  $Ag_c(x_1, \dots, x_{n-1}) = Ag_c(x_1, \dots, x_n)$ . So  $\Omega : \{(x, y) : x < y\}$

The next program computes  $\psi(x, y)$ :

```
def psi(x, y):
    return x
```

The complexity of  $\psi(x, y, l)$  is  $\mathcal{O}(1)$  in  $\Omega$ .

Similar considerations can be done for Maximum.  $\square$

**Lemma 11.** Product is a  $\mathcal{O}(1)$ -decreasing  $\psi$ -recursive computable aggregation.

*Proof.*  $Ag_c(x_1, \dots, x_n) = \prod_{i=1}^n x_i = x_n * \prod_{i=1}^{n-1} x_i$

So  $Ag_c(x_1, \dots, x_n) = x_n * Ag_c(x_1, \dots, x_{n-1})$  and  $\psi(x, y) = x/y$ .

The next program computes  $\psi(x, y)$ :

```
def psi(x, y):
    return x/y
```

So  $\psi$  has  $\mathcal{O}(1)$  constant complexity cost.  $\square$

**Lemma 12.** Geometric mean is a  $\mathcal{O}(1)$ -decreasing  $\psi$ -recursive computable aggregations if  $n$  is known.

*Proof.*  $Ag_c(x_1, \dots, x_{n-1}) = (\prod_{i=1}^{n-1} x_i)^{\frac{1}{n-1}} = \frac{x_n}{x_n} ((\prod_{i=1}^{n-1} x_i)^{\frac{1}{n-1}})^{\frac{n}{n-1}} = \frac{1}{x_n} ((\prod_{i=1}^n x_i)^{\frac{1}{n}})^{\frac{n}{n-1}} = \frac{1}{x_n} Ag_c(x_1, \dots, x_n)^{\frac{n}{n-1}}$

So  $\psi(x, y, n) = \frac{1}{y} x^{\frac{n}{n-1}}$   $\square$

The next program computes  $\psi(x, y, n)$ :



Aggregation	$\psi$	Complexity of $\psi$	$\Omega$
Arithmetic mean	$\frac{n}{n-1}x + \frac{1}{n-1}y$	$\mathcal{O}(1), \mathcal{O}(n)$	$\mathbb{R}^2$
Product	$x/y$	$\mathcal{O}(1)$	$\mathbb{R}^2$
Geometric mean	$\frac{1}{y}x^{\frac{n}{n-1}}$	$\mathcal{O}(1), \mathcal{O}(n)$	$\mathbb{R}^2$
Minimum	$x$	$\mathcal{O}(1)$	$x < y$
Maximum	$x$	$\mathcal{O}(1)$	$x > y$
Bounded sum	$x - y$	$\mathcal{O}(1)$	$x < 1$

TABLE II

EXPANSION FUNCTIONS COMPLEXITY COST OF SOME DECREASING  $\psi$ -RECURSIVE COMPUTABLE AGGREGATIONS.

```
def phi(x, y, n):
    return res x**(n/(n-1))/y
```

So  $\psi$  has  $\mathcal{O}(1)$  constant complexity cost if  $n$  is known.

**Lemma 13.** *Bounded sum ( $\min\{1, \sum_{i=1}^n x_i\}$ ) is a  $\mathcal{O}(1)$ -decreasing  $\psi$ -recursive computable aggregations.*

*Proof.* If  $Ag_c(x_1, \dots, x_n) < 1$ , then  $Ag_c(x_1, \dots, x_{n-1}) = Ag_c(x_1, \dots, x_n) - x_n$ . So  $\Omega : \{(x, y) : x < 1\}$

The next program computes  $\psi(x, y)$ :

```
def phi(x, y):
    if x < 1:
        res = x - y
    return res
```

So  $\psi$  has  $\mathcal{O}(1)$  constant complexity cost. □

**Lemma 14.** *Let  $Ag_{c\mathcal{O}(f(n))}$  and  $Ag_{c\mathcal{O}(g(n))}$  be the sets of  $\mathcal{O}(f(n))$ -decreasing  $\psi$ -recursive and  $\mathcal{O}(g(n))$ -decreasing  $\psi$ -recursive computable aggregations respectively. If  $f(n)$  belongs to  $\mathcal{O}(g(n))$ , then*

$$Ag_{c\mathcal{O}(f(n))} \subseteq Ag_{c\mathcal{O}(g(n))}$$

*Proof.* Trivial. □

## V. CONCLUSIONS

The main goal in this paper is to study the behaviour of computable recursive aggregations when the universe of discourse is changed. It is possible to classify computable recursive aggregations by the complexity of their expansion and the reduction function complexity cost. Moreover, it is found a relation between the complexity of a computable recursive aggregation and its expansion function cost complexity.

## ACKNOWLEDGMENT

This research has been partially supported by the Government of Spain (grant TIN2015-66471-P), the Government of Madrid (grant S2013/ICE-2845) and Complutense University (UCM Research Group 910149).

## REFERENCES

[1] G. Barnett and L. Del Tonga. *Data Structures and Algorithms*. DotNet-Slackert, 2008.  
 [2] G. Beliakov, A. Pradera and T. Calvo. *Aggregations Functions: A guide for Practitioners*. Springer, 2007.  
 [3] B. Brassard. *Fundamentals of Algorithmics*. Pearson, 2015.  
 [4] H. Bustince, B. De Baets, J. Fernandez, R. Mesiar and J. Montero. A generalization of the migrativity property of aggregation functions. *Information Sciences*, 191:76 – 85, 2012.

[5] V. Cutello and J. Montero. Recursive connective rules. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 2(14):3–20, 1999.  
 [6] A. del Amo, J. Montero and E. Molina. Representation of consistent recursive rules. *European Journal of Operational Research*, 130(1):29–53, 2001.  
 [7] D. Gómez and J. Montero. A discussion on aggregations operators. *Kybernetika*, 40:107–120, 2004.  
 [8] R. González del Campo, L. Garmendia and J. Montero. Expansible computable aggregation rules. In *Proceedings of the 2015 International Conference on Intelligent Systems and Knowledge Engineering, ISKE 2015, Taipei, Taiwan*, pages 8–11, November 2015.  
 [9] A. Kolesárová, R. Mesiar and J. Montero. Sequential aggregation of bags. *Information Sciences*, 294:305–314, 2015.  
 [10] J. Giancarlo Lucca, G. Pereira Dimuro, B. R. C. Bedregal, R. Mesiar, A.árová and H. Bustince. Preaggregation functions: Construction and an application. *IEEE Trans. Fuzzy Systems*, 24(2):260–272, 2016.  
 [11] J. Montero, R. González del Campo, L. Garmendia, D. Gómez and J. Tinguaro. Computable aggregations. *Information Sciences*, 2, 2017.

# Relaciones de Indistinguibilidad Definidas Positivas

J. Recasens

Depto. Tecnología de la Arquitectura  
Universidad Politécnica de Cataluña  
Sant Cugat del Vallès  
j.recasens@upc.edu

M. Santos Tomás

Depto. Tecnología de la Arquitectura  
Universidad Politécnica de Cataluña  
Barcelona  
maria.santos.tomas@upc.edu

**Resumen**—Se proporcionan dos caracterizaciones geométricas de las relaciones borrosas reflexivas y simétricas definidas positivas basadas en la inmersión isométrica de sus pseudodistancias naturalmente asociadas respecto a las t-normas arquimedianas continuas con generadores aditivos  $t(x) = \arccos x$  y  $t(x) = \sqrt{1-x}$ .

Dada la importancia de la t-norma  $T_{\arccos x}$  con generador aditivo  $t(x) = \arccos x$  en estas caracterizaciones, también se caracterizará dicha t-norma.

**Palabras clave:** t-norma, t-norma arquimediana continua, generador aditivo, relación de T-indistinguibilidad, distancia, matriz definida positiva, determinante de Cayley-Menger.

## I. INTRODUCCIÓN

En el volumen 157 de la revista Fuzzy Sets and Systems aparecen publicados dos artículos ([8], [13]) que estudian la relación entre la propiedad de ser definida positiva y la transitividad de una relación borrosa reflexiva y simétrica desde dos puntos de vista diferentes. En [13] el interés está en el estudio de medidas de similitud usualmente usadas en, por ejemplo, química combinatoria mientras que en [8] el foco está puesto en la caracterización de kernels (ver también [9]). Uno de los resultados más importantes compartidos por ambos artículos es que una relación borrosa reflexiva y simétrica es tres-definida semipositiva (ver Definición III.2) si, y sólo si, es  $T_{\arccos}$ -transitiva (es decir, una relación de  $T_{\arccos}$ -indistinguibilidad) donde  $T_{\arccos}$  es la t-norma arquimediana continua con generador aditivo  $t(x) = \arccos x$ . En [13] también se analiza la relación entre ser definida positiva y la t-norma con generador aditivo  $t(x) = \sqrt{1-x}$ . La transitividad respecto a esta t-norma también se considera en el estudio de particiones borrosas en otro artículo del mismo volumen de Fuzzy Sets and Systems [4]. Más tarde, también en esta revista, [3] insiste en considerar el problema abierto de caracterizar las relaciones borrosas reflexivas y simétricas definidas positivas.

Es, en efecto, un problema interesante y el presente trabajo proporciona dos caracterizaciones geométricas de dichas relaciones. Tras una sección de cuestiones preliminares, la sección III estudia y caracteriza la importante t-norma arquimediana continua  $T_{\arccos}$  con generador aditivo  $t(x) = \arccos x$  al relacionarlo con la anulación del determinante de relaciones de T-indistinguibilidad unidimensionales (ver Definición III.5). Los resultados de la sección IV proporcionan caracterizaciones de una relación borrosa reflexiva y simétrica definida positiva A basadas en la inmersión isométrica de pseudodistancias asociadas a A (Proposición II.9) mediante  $T_{\sqrt{1-x}}$  y  $T_{\arccos}$  en un espacio euclídeo y en una hiperesfera.

## II. PRELIMINARES

Esta sección contiene las definiciones y propiedades básicas relativas a t-normas, relaciones de T-indistinguibilidad y matrices definidas positivas que se necesitarán a lo largo del trabajo. Empecemos recordando la caracterización de las t-normas arquimedianas continuas por sus generadores aditivos.

**Proposición II.1.** [7] Una t-norma T es arquimediana continua si, y sólo si, existe una función  $t : [0, 1] \rightarrow [0, \infty]$  decreciente y continua con  $t(1) = 0$  tal que para todo  $x, y \in [0, 1]$

$$T(x, y) = t^{[-1]}(t(x) + t(y))$$

donde  $t^{[-1]}$  es la pseudo inversa de t definida por

$$t^{[-1]}(x) = \begin{cases} t^{-1}(x) & \text{si } x \in [0, t(0)] \\ 0 & \text{en caso contrario.} \end{cases}$$

T es estricta si  $t(0) = \infty$  y no estricta en caso contrario. t se denomina un generador aditivo de T y dos generadores aditivos de la misma t-norma difieren sólo en una constante multiplicativa positiva.

A partir de una t-norma continua por la izquierda se puede definir su residuación y birresiduación. Si la t-norma se usa para modelizar la conjunción lógica, entonces su residuación y birresiduación representan la implicación y biimplicación lógicas respectivamente.

**Definición II.2.** [7] Sea T una t-norma continua por la izquierda.

- La residuación  $\vec{T}$  de T es la aplicación  $\vec{T} : [0, 1] \times [0, 1] \rightarrow [0, 1]$  definida para todo  $x, y \in [0, 1]$  por

$$\vec{T}(x, y) = \sup\{\alpha \in [0, 1] \mid T(x, \alpha) \leq y\}.$$

- La birresiduación  $\overleftarrow{T}$  de T es la aplicación  $\overleftarrow{T} : [0, 1] \times [0, 1] \rightarrow [0, 1]$  definida para todo  $x, y \in [0, 1]$  por

$$\overleftarrow{T}(x, y) = \min(\vec{T}(x, y), \vec{T}(y, x)).$$

**Proposición II.3.** [7] Sea T una t-norma arquimediana continua y t un generador aditivo de T. Entonces para todo  $x, y \in [0, 1]$

- $$\vec{T}(x, y) = t^{[-1]}(t(y) - t(x)).$$

- $$\overleftarrow{T}(x, y) = t^{-1}(|t(x) - t(y)|).$$



Necesitaremos el siguiente resultado que afirma que una t-norma continua por la izquierda puede recuperarse de su residuación.

**Proposición II.4.** [1] Una t-norma es continua por la izquierda si, y sólo si,  $\inf\{\alpha \in [0, 1] \mid \vec{T}(x, \alpha) \geq y\} = T(x, y)$  para todo  $x, y \in [0, 1]$ .

Gracias a esta proposición, una t-norma continua por la izquierda puede recuperarse a partir de su residuación y por tanto la t-norma está caracterizado por ella. No es el caso cuando  $T$  no es continua por la izquierda tal como muestra el siguiente ejemplo.

**Ejemplo II.5.** [1] Consideremos las dos t-normas (no continuas por la izquierda)  $T_1$  y  $T_2$  definidas por

$$T_1(x, y) = \begin{cases} 0 & \text{si } (x, y) \in [0, \frac{1}{2}] \times [0, \frac{1}{2}] \\ \min(x, y) & \text{en caso contrario} \end{cases}$$

$$T_2(x, y) = \begin{cases} T_1(x, y) & \text{si } (x, y) \neq (\frac{1}{2}, \frac{1}{2}) \\ \frac{1}{2} & \text{si } (x, y) = (\frac{1}{2}, \frac{1}{2}). \end{cases}$$

$T_1 \neq T_2$  pero  $\vec{T}_1 = \vec{T}_2$ .

Las relaciones de indistinguibilidad son uno de los tipos de relaciones borrosas más importantes porque borrosifican los conceptos de equivalencia e igualdad. Han sido estudiadas extensivamente tanto desde el punto de vista teórico como aplicado. En [10] el lector puede hallar un panorama general de dichas relaciones.

**Definición II.6.** [10], [15] Sea  $T$  una t-norma y  $X$  un conjunto. Una relación borrosa  $E$  en  $X$  es una relación de  $T$ -indistinguibilidad si, y sólo si, para todo  $x, y, z \in X$

- $E(x, x) = 1$  (Reflexividad)
- $E(x, y) = E(y, x)$  (Simetría)
- $T(E(x, y), E(y, z)) \leq E(x, z)$  ( $T$ -transitividad).

Si  $E(x, y) = 1$  si, y sólo si,  $x = y$ , entonces se dice que  $E$  separa puntos.

**Definición II.7.** Una relación borrosa reflexiva y simétrica  $E$  en  $X$  se llama un relación de proximidad o de tolerancia.

Las relaciones de indistinguibilidad están relacionadas con distancias desde diferentes puntos de vista. Uno que se necesitará en la sección IV es el resultado enunciado en la Proposición II.9.

**Definición II.8.** Sea  $X$  un conjunto. Una aplicación  $d : X \times X \rightarrow [0, \infty]$  es una pseudodistancia o pseudométrica si, y sólo si, para todo  $x, y, z \in X$

- $d(x, x) = 0$
- $d(x, y) = d(y, x)$
- $d(x, y) + d(y, z) \geq d(x, z)$

Si  $d(x, y) = 0$  si, y sólo si,  $x = y$ , entonces  $d$  es una distancia o métrica en  $X$ .

**Proposición II.9.** [14] Sea  $T$  una t-norma arquimediana continua,  $t$  un generador aditivo de  $T$  y  $X$  un conjunto. Una relación borrosa  $E$  en  $X$  es una relación de  $T$ -indistinguibilidad

si, y sólo si,  $t(E)$  es una pseudodistancia en  $X$ .  $E$  separa puntos si, y sólo si,  $t(E)$  es una distancia.

Recordemos finalmente la definición de matriz definida positiva.

**Definición II.10.** Una matriz real  $A$  simétrica  $n \times n$  es definida positiva si  $\vec{u}^t A \vec{u} > 0$  para todo vector no nulo  $\vec{u} \in \mathbb{R}^n$  y definida semipositiva si  $\vec{u}^t A \vec{u} \geq 0$ .

Hay muchas caracterizaciones de las matrices definidas positivas. La siguiente proposición recuerda un par de ellas.

**Proposición II.11.** Sea  $A$  una matriz real simétrica  $n \times n$ . Las siguientes afirmaciones son equivalentes.

- $A$  es definida definida positiva.
- Todos los valores propios de  $A$  son positivos.
- Todos los menores principales de  $A$  son positivos, donde el  $k$ -ésimo menor principal de  $A$  es el determinante de su submatriz compuesta por sus  $k$  primeras filas y  $k$  primeras columnas.

### III. CARACTERIZACIÓN DE $T_{\arccos}$

Tal como se mencionó en la sección introductoria, la t-norma arquimediana continua  $T_{\arccos}$  con generador aditivo  $t(x) = \arccos x$  desempeña un papel importante en la caracterización de las relaciones borrosas definidas semipositivas. Por ejemplo, una relación borrosa reflexiva y simétrica es tres definida positiva (Definición III.2) si, y sólo si, es una relación de  $T_{\arccos}$ -indistinguibilidad. Esto hace especial a esta t-norma y merece la pena estudiarla con detalle. Además, en la subsección IV.1,  $T_{\arccos}$  se usará para caracterizar geoméricamente las relaciones borrosas reflexivas y simétricas definidas positivas. En esta sección se dará una caracterización de esta t-norma a partir de relaciones de indistinguibilidad unidimensionales (ver Definición III.5).

La siguiente proposición describe explícitamente la t-norma  $T_{\arccos}$  y sus residuación y birresiduación.

**Proposición III.1.** Para todo  $x, y \in [0, 1]$ ,

▪

$$T_{\arccos}(x, y) = \begin{aligned} & \max(\cos(\arccos x + \arccos y), 0) \\ & = \max(xy - \sqrt{1-x^2}\sqrt{1-y^2}, 0) \end{aligned}$$

▪

$$\vec{T}_{\arccos}(x, y) = \begin{aligned} & \cos(\max(0, \arccos y - \arccos x)) \\ & = \begin{cases} 1 & \text{si } x \leq y \\ xy + \sqrt{1-x^2}\sqrt{1-y^2} & \text{si } x > y. \end{cases} \end{aligned}$$

▪

$$\overleftarrow{T}_{\arccos}(x, y) = \begin{aligned} & \cos(|\arccos x - \arccos y|) \\ & = \cos(\arccos x - \arccos y) \\ & = xy + \sqrt{1-x^2}\sqrt{1-y^2}. \end{aligned}$$

**Definición III.2.** [13] Una relación borrosa  $A$  reflexiva y simétrica en un conjunto  $X = \{x_1, x_2, \dots, x_n\}$  de cardinal  $n > 2$

es tres-definida semipositiva si para todo  $0 \leq i, j, k \leq n$ ,  $i \neq j \neq k \neq i$  la submatriz de  $A$

$$\begin{pmatrix} 1 & a_{ij} & a_{ik} \\ a_{ij} & 1 & a_{jk} \\ a_{ik} & a_{jk} & 1 \end{pmatrix}$$

es definida semipositiva, donde  $A(x_i, x_j) = a_{ij}$ .

En [8], [13] se da la siguiente caracterización de las relaciones de tolerancia tres-definidas semipositivas.

**Proposición III.3.** [8], [13] Una relación borrosa  $A$  reflexiva y simétrica en un conjunto  $X$  es tres definida semipositiva si, Y sólo si, es  $T_{\arccos}$ -transitiva (i.e.: es una relación de  $T_{\arccos}$ -indistinguibilidad).

La proposición anterior tiene esta bonita interpretación geométrica.

- Si  $A = (a_{ij})_{i,j=1,2,3}$  es una matriz  $3 \times 3$  definida positiva, entonces es la matriz de un producto escalar  $\langle \cdot, \cdot \rangle$  y se pueden hallar tres vectores  $\vec{u}_1, \vec{u}_2, \vec{u}_3$  linealmente independientes con  $a_{ij} = \langle \vec{u}_i, \vec{u}_j \rangle$ .  $a_{ii} = 1$  significa que estos vectores son unitarios y el ángulo determinado por  $\vec{u}_i$  y  $\vec{u}_j$  es por tanto  $\arccos a_{ij}$ . La Proposición III.3 dice que para que estos vectores existan estos ángulos deben verificar la desigualdad triangular; en otras palabras, la suma de dos de ellos debe ser mayor o igual que el otro.
- Se puede obtener otra interpretación geométrica teniendo en cuenta que  $\arccos a_{ij}$  también es la longitud del arco que une los extremos de los vectores  $\vec{u}_i$  y  $\vec{u}_j$  con sus orígenes en el origen de coordenadas en la esfera de centro el origen de coordenadas y radio 1. Así la matriz  $A$  es tres-definida semipositiva si, y sólo si, las longitudes de los tres ángulos satisfacen la desigualdad triangular. Esto se generalizará en la subsección IV.2.

La siguiente proposición presenta la forma más natural de generar una relación de  $T$ -indistinguibilidad a partir de un subconjunto borroso de un universo  $X$ . Generaliza (borrosifica) el hecho de que, en el caso crisp, un subconjunto (crisp)  $A \subseteq X$  particiona  $X$  en dos partes:  $A$  y su complementario  $X - A$ .

**Proposición III.4.** [10], [14] Sea  $\mu$  un subconjunto borroso de  $X$  y  $T$  una  $t$ -norma continua por la izquierda. La relación borrosa  $E_\mu$  de  $X$  definida para todo  $x, y \in X$  por

$$E_\mu(x, y) = \overleftrightarrow{T}(\mu(x), \mu(y))$$

es una relación de  $T$ -indistinguibilidad.

**Definición III.5.** [5], [10] Una relación de  $T$ -indistinguibilidad de  $X$  de la forma  $E_\mu$  para algún subconjunto borroso  $\mu$  de  $X$  se llama unidimensional.

**Lema III.6.** Sea  $T$  una  $t$ -norma arquimediana continua no estricta,  $t$  un generador aditivo de  $T$  y  $\mu$  un subconjunto borroso de un conjunto  $X$  de cardinal finito. Entonces existe un subconjunto borroso  $\nu$  normalizado tal que  $E_\mu = E_\nu$ .

*Demostración.* Considérese  $k = \max\{-t(\mu(x)) \mid x \in X\}$  y  $\nu$  definido para todo  $x \in X$  por

$$\nu(x) = t^{-1}(t(\mu(x)) + k).$$

- $\nu$  es normalizado: Sea  $x_0 \in X$  tal que  $k = -t(\mu(x_0))$ . Entonces  $\nu(x_0) = t^{-1}(t(\mu(x_0)) - t(\mu(x_0))) = t^{-1}(0) = 1$ .
- $E_\nu = E_\mu$ :

$$\begin{aligned} E_\nu(x, y) &= t^{-1}(|t(t^{-1}(t(\mu(x)) + k)) - t(t^{-1}(t(\mu(y)) + k))|) \\ &= t^{-1}(|t(\mu(x)) - t(\mu(y))|) = E_\mu(x, y). \end{aligned}$$

□

**Lema III.7.** Sea  $T$  una  $t$ -norma continua por la izquierda,  $X$  un conjunto de cardinal finito y  $\mu$  un subconjunto borroso de  $X$  constante. Entonces  $E_\mu(x, y) = 1$  para todo  $x, y \in X$  y por consiguiente el rango de  $E_\mu$  es 1 ( $\text{rg}(E_\mu) = 1$ ).

*Demostración.* Trivial. □

La siguiente proposición caracteriza la  $t$ -norma  $T_{\arccos}$  como la única para la cual  $\det(E_\mu) = 0$  para todo subconjunto borroso de un conjunto de cardinal 3.

**Proposición III.8.** Sea  $X = \{x_1, x_2, x_3\}$  un conjunto de cardinal 3 y  $T$  una  $t$ -norma continua por la izquierda.  $\det(E_\mu) = 0$  para todo subconjunto borroso  $\mu$  de  $X$  si, y sólo si  $T = T_{\arccos}$ .

*Demostración.* Gracias al lema anterior podemos considerar que el subconjunto  $\mu$  de  $X$  está normalizado y, sin pérdida de generalidad, de la forma  $\mu = (1, x, y)$  con  $x, y \in [0, 1]$  y  $1 \geq x \geq y$ . Entonces,

$$\begin{aligned} E_\mu &= \begin{pmatrix} 1 & x & y \\ x & 1 & \overleftarrow{T}(x, y) \\ y & \overleftarrow{T}(x, y) & 1 \end{pmatrix} \\ &= \begin{pmatrix} 1 & x & y \\ x & 1 & \overrightarrow{T}(x, y) \\ y & \overrightarrow{T}(x, y) & 1 \end{pmatrix}. \end{aligned}$$

$\det(E_\mu) = 1 + 2xy\overrightarrow{T}(x, y) - x^2 - y^2 - (\overrightarrow{T}(x, y))^2 = 0$  si, y sólo si,  $\overrightarrow{T}(x, y) = xy + \sqrt{1-x^2}\sqrt{1-y^2}$ .

Siendo esto cierto para todo  $x, y \in [0, 1]$  con  $x \geq y$ , y gracias a la Proposición II.4 se tiene que  $T = T_{\arccos}$ . □

Otro forma de expresar este resultado es la siguiente proposición.

**Proposición III.9.** Sea  $X = \{x_1, x_2, x_3\}$  un conjunto de cardinal 3 y  $T$  una  $t$ -norma continua por la izquierda.  $\text{rg}(E_\mu) = 2$  para todo subconjunto borroso  $\mu$  de  $X$  no constante si, y sólo si  $T = T_{\arccos}$ .

El siguiente resultado generaliza la proposición anterior en una dirección.

**Proposición III.10.** Sea  $X = \{x_1, x_2, \dots, x_n\}$  un conjunto finito de cardinal  $n \geq 2$ ,  $\mu$  un subconjunto borroso no constante de  $X$  y  $E_\mu$  la relación de  $T_{\arccos}$ -indistinguibilidad unidimensional de  $X$  generada por  $\mu$ . Entonces  $\text{rg}(E_\mu) = 2$ .



*Demostración.* Sin pérdida de generalidad podemos asumir que  $\mu = (1, a_2, a_3, \dots, a_n)$  con  $1 \geq a_2 \geq a_3, \geq \dots \geq a_n$  y podemos escribir  $\mu = (1, \cos b_2, \cos b_3, \dots, \cos b_n)$ . Dado que  $\mu$  es no constante,  $a_n \neq 1$  y por tanto  $\cos b_n \neq 1$  y  $\sin b_n \neq 0$ . Entonces

$$\text{rg}(E_\mu) = \text{rg} \begin{pmatrix} 1 & a_2 & a_3 & \dots & a_n \\ a_2 & 1 & \overrightarrow{T}(a_2, a_3) & \dots & \overrightarrow{T}(a_2, a_n) \\ a_3 & \overrightarrow{T}(a_2, a_3) & 1 & \dots & \overrightarrow{T}(a_3, a_n) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_n & \overrightarrow{T}(a_2, a_n) & \overrightarrow{T}(a_3, a_n) & \dots & 1 \end{pmatrix} =$$

$$\text{rg} \begin{pmatrix} 1 & \cos b_2 & \cos b_3 & \dots & \cos b_n \\ \cos b_2 & 1 & \cos(b_3 - b_2) & \dots & \cos(b_n - b_2) \\ \cos b_3 & \cos(b_3 - b_2) & 1 & \dots & \cos(b_n - b_3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \cos b_n & \cos(b_n - b_2) & \cos(b_n - b_3) & \dots & 1 \end{pmatrix}.$$

Restando a la  $i$ -ésima columna,  $i > 1$ , la primera multiplicada por  $\cos b_i$  se obtiene que el rango es

$$\text{rg} \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ \cos b_2 & 1 - \cos^2 b_2 & \sin b_3 \sin b_2 & \dots & \sin b_n \sin b_2 \\ \cos b_3 & \sin b_3 \sin b_2 & 1 - \cos^2 b_3 & \dots & \sin b_n \sin b_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \cos b_n & \sin b_n \sin b_2 & \sin b_n \sin b_3 & \dots & 1 - \cos^2 b_n \end{pmatrix} =$$

$$1 + \text{rg} \begin{pmatrix} 1 - \cos^2 b_2 & \sin b_3 \sin b_2 & \dots & \sin b_n \sin b_2 \\ \sin b_3 \sin b_2 & 1 - \cos^2 b_3 & \dots & \sin b_n \sin b_3 \\ \vdots & \vdots & \ddots & \vdots \\ \sin b_n \sin b_2 & \sin b_n \sin b_3 & \dots & 1 - \cos^2 b_n \end{pmatrix} =$$

$$1 + \text{rg} \begin{pmatrix} \sin^2 b_2 & \sin b_3 \sin b_2 & \dots & \sin b_n \sin b_2 \\ \sin b_3 \sin b_2 & \sin^2 b_3 & \dots & \sin b_n \sin b_3 \\ \vdots & \vdots & \ddots & \vdots \\ \sin b_n \sin b_2 & \sin b_n \sin b_3 & \dots & \sin^2 b_n \end{pmatrix}$$

Restando a la  $i$ -ésima columna,  $i < n$ , la última multiplicada por  $\frac{\sin b_i}{\sin b_n}$  (recuérdese que  $\sin b_n \neq 0$ ) se obtiene que el rango de  $E_\mu$  es

$$1 + \text{rg} \begin{pmatrix} 0 & 0 & \dots & \sin b_n \sin b_2 \\ 0 & 0 & \dots & \sin b_n \sin b_3 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sin^2 b_n \end{pmatrix} = 2.$$

□

Como corolario se obtiene la siguiente caracterización de la  $t$ -norma  $T_{\text{arc cos}}$ .

**Proposición III.11.** *Sea  $T$  una  $t$ -norma continua por la izquierda y  $X$  un conjunto finito de cardinal  $n > 2$ .  $T = T_{\text{arc cos}}$  si, y sólo si,  $\text{rg}(E_\mu) = 2$  para todo subconjunto borroso  $\mu$  no constante de  $X$ .*

*Demostración.*

⇒) Proposición III.10.

⇐) Consideremos una  $t$ -norma  $T$  diferente de  $T_{\text{arc cos}}$  y  $\mu$  un subconjunto borroso de  $X$  de la forma  $(1, a_2, a_3, \dots, a_n)$  con  $1 > a_2 > a_3$  y con  $\overrightarrow{T}(a_2, a_3) \neq \overrightarrow{T}_{\text{arc cos}}(a_2, a_3)$ . (Tales  $a_2, a_3$  existen gracias a la Proposición II.4). Entonces

$$\det \begin{pmatrix} 1 & a_2 & a_3 \\ a_2 & 1 & \overrightarrow{T}(a_2, a_3) \\ a_3 & \overrightarrow{T}(a_2, a_3) & 1 \end{pmatrix}$$

$$= \det \begin{pmatrix} 1 & a_2 & a_3 \\ a_2 & 1 & \overrightarrow{T}(a_2, a_3) \\ a_3 & \overrightarrow{T}(a_2, a_3) & 1 \end{pmatrix}.$$

Este determinante es diferente de 0 gracias a la Proposición III.8 y por tanto  $\text{rg}(E_\mu) \geq 3$ . □

#### IV. DOS CARACTERIZACIONES GEOMÉTRICAS DE LAS RELACIONES BORROSAS REFLEXIVAS Y SIMÉTRICAS DEFINIDAS POSITIVAS

De la sección anterior se tiene que una relación borrosa reflexiva y simétrica en un conjunto  $X$  de cardinal 3 es  $T_{\text{arc cos}}$ -transitiva si, y sólo si, es definida semipositiva. Si  $X$  es de cardinal mayor que 3, la condición es necesaria, pero no suficiente como se muestra en [8] mediante un contraejemplo.

Esta sección contiene dos caracterizaciones de las relaciones borrosas reflexivas y simétricas definidas positivas: en la subsección IV-A relacionada con la inmersión isométrica en un espacio euclídeo y en la subsección IV-B relacionada con la inmersión isométrica en la hipersfera  $\mathbb{S}^n = \{\vec{v} = (x_0, x_1, \dots, x_n) \in \mathbb{R}^{n+1} \mid \sum_{i=0}^n x_i^2 = 1\}$  en  $\mathbb{R}^{n+1}$  de centro el origen de coordenadas  $\vec{0}$  y radio 1.

##### IV-A. Inmersión en $\mathbb{R}^n$

**Definición IV.1.** *Sea  $X = \{x_0, x_1, \dots, x_n\}$  un conjunto finito de cardinal  $n+1$  y  $d$  una distancia en  $X$ . Denotando  $d(x_i, x_j)$  por  $d_{ij}$  para todo  $0 \leq i, j \leq n$ , el determinante de Cayley-Menger  $CM(x_0, x_1, \dots, x_n)$  es*

$$\begin{vmatrix} 0 & 1 & 1 & 1 & \dots & 1 \\ 1 & 0 & d_{01}^2 & d_{02}^2 & \dots & d_{0n}^2 \\ 1 & d_{01}^2 & 0 & d_{12}^2 & \dots & d_{1n}^2 \\ 1 & d_{02}^2 & d_{12}^2 & 0 & \dots & d_{2n}^2 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & d_{0n}^2 & d_{1n}^2 & d_{2n}^2 & \dots & 0 \end{vmatrix}$$

La importancia de este determinante estriba en el hecho de que si el conjunto  $X$  está contenido en  $\mathbb{R}^n$  y  $d$  es la distancia euclídea, entonces está relacionado con el volumen del  $n+1$ -simplex generado por los puntos de  $X$  del siguiente modo.

**Proposición IV.2.** *Sea  $X = \{x_0, x_1, \dots, x_n\}$  un conjunto finito de  $n+1$  puntos de  $\mathbb{R}^n$  y  $d$  la distancia euclídea. Entonces el volumen  $v(X)$  del  $n+1$ -simplex con vértices los elementos de  $X$  es*

$$v(X) = \sqrt{\frac{(-1)^{n+1}}{2^n (n!)^2} CM(x_0, x_1, \dots, x_n)}.$$

Este resultado se puede consultar en cualquier libro y artículo que estudie las inmersiones en un espacio euclídeo. Uno de los primeros, citado en [6], es [12]. En particular, el determinante de Cayley-Menger de un conjunto de puntos de  $\mathbb{R}^n$  debe tener el mismo signo que  $(-1)^{n+1}$ . De aquí se obtiene la siguiente caracterización de los espacios métricos finitos que se pueden inyectar isométricamente en un espacio euclídeo.

**Proposición IV.3.** [6] Sea  $X = \{x_0, x_1, \dots, x_n\}$  un conjunto finito de cardinal  $n+1$  y  $d$  una distancia en  $X$ . Denotando  $d(x_i, x_j)$  by  $d_{ij}$  para todo  $0 \leq i, j \leq n$ ,  $(X, d)$  es inyectable isométricamente en  $\mathbb{R}^n$  si y sólo si, para todo  $k = 1, 2, \dots, n$  el signo de  $CM(x_0, x_1, \dots, x_k)$  es igual a  $(-1)^{k+1}$ .

**Proposición IV.4.** [11] Sea  $X = \{x_0, x_1, \dots, x_n\}$  un conjunto finito de cardinal  $n+1$  y  $d$  una distancia en  $X$ . Denotando  $d(x_i, x_j)$  por  $d_{ij}$  para todo  $0 \leq i, j \leq n$ ,  $(X, d)$  es inyectable isométricamente en  $\mathbb{R}^n$  si, y sólo si, la matriz  $n \times n$  con valores  $x_{ij} = \frac{d_{0i}^2 + d_{0j}^2 - d_{ij}^2}{2}$  ( $1 \leq i, j \leq n$ ) es definida positiva.

En el caso de una relación borrosa reflexiva y simétrica, su matriz  $A$  asociada  $n \times n$  tiene unos en la diagonal, así que para todo  $i = 1, 2, \dots, n$ , se tiene

$$1 = x_{ii} = \frac{d_{0i}^2 + d_{0i}^2 - d_{ii}^2}{2} = \frac{2d_{0i}^2}{2} = d_{0i}^2.$$

y, por lo tanto,

$$d_{0i} = 1.$$

Así en este caso el determinante de Cayley-Menger de  $d$  es

$$\begin{vmatrix} 0 & 1 & 1 & 1 & \dots & 1 \\ 1 & 0 & 1 & 1 & \dots & 1 \\ 1 & 1 & 0 & d_{12}^2 & \dots & d_{1n}^2 \\ 1 & 1 & d_{12}^2 & 0 & \dots & d_{2n}^2 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & d_{1n}^2 & d_{2n}^2 & \dots & 0 \end{vmatrix}$$

Además, de

$$x_{ij} = \frac{d_{0i}^2 + d_{0j}^2 - d_{ij}^2}{2} = \frac{2 - d_{ij}^2}{2}$$

se obtiene

$$d_{ij} = \sqrt{2} \sqrt{1 - x_{ij}} \text{ para todo } 1 \leq i, j \leq n.$$

En términos de los elementos de  $A$ , entonces

$$CM(x_0, x_1, \dots, x_n) = \begin{vmatrix} 0 & 1 & 1 & 1 & \dots & 1 \\ 1 & 0 & 1 & 1 & \dots & 1 \\ 1 & 1 & 0 & 2(1-x_{12}) & \dots & 2(1-x_{1n}) \\ 1 & 1 & 2(1-x_{12}) & 0 & \dots & 2(1-x_{2n}) \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & 2(1-x_{1n}) & 2(1-x_{2n}) & \dots & 0 \end{vmatrix}$$

y se obtiene la siguiente caracterización geométrica de las relaciones borrosas reflexivas y simétrica con matriz asociada definida positiva.

**Proposición IV.5.** Una relación borrosa reflexiva y simétrica  $A$  en un conjunto  $X = \{x_1, x_2, \dots, x_n\}$  finito es definida positiva si, y sólo si, es una relación de  $T_{\sqrt{1-x}}$ -indistinguibilidad y en  $X' = X \cup \{x_0\}$  la distancia asociada  $d$  (i.e.:  $d_{ij} = \sqrt{2} \sqrt{1-x_{ij}}$  si  $i, j > 0$  y  $d_{0i} = 1$  para  $i > 0$ ) es inyectable isométricamente en  $\mathbb{R}^n$ .

En la inmersión,  $x_0$  puede enviarse al origen de coordenadas  $x'_0$  y las imágenes  $x'_i$  de  $x_i, i > 0$  corresponden a los extremos de los vectores  $\overrightarrow{x'_0 x'_i}$  con lo que la proposición anterior se puede enunciar de modo más claro.

**Proposición IV.6.** Una relación borrosa  $A = (x_{ij})$  reflexiva y simétrica en un conjunto  $X = \{x_1, x_2, \dots, x_n\}$  de cardinal finito  $n$  es definida positiva si, y sólo si, es una relación de  $T_{\sqrt{1-x}}$ -indistinguibilidad y  $X$  con la distancia  $d(x_i, x_j) = \sqrt{2} \sqrt{1-x_{ij}}$ ,  $1 \leq i, j \leq n$ , se puede inyectar isométricamente en  $\mathbb{R}^n$  de tal modo que las imágenes de los puntos de  $X$  están situados sobre la hipersfera  $\mathbb{S}^{n-1}$ .

En particular, para un conjunto  $X$  de cardinal 3 esto significa que el determinante

$$\begin{vmatrix} 0 & 1 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 & 1 \\ 1 & 1 & 0 & 2(1-x_{12}) & 2(1-x_{13}) \\ 1 & 1 & 2(1-x_{12}) & 0 & 2(1-x_{23}) \\ 1 & 1 & 2(1-x_{13}) & 2(1-x_{23}) & 0 \end{vmatrix} = 8(x_{12}x_{13}x_{23} - x_{12}^2 - x_{13}^2 - x_{23}^2 + 1)$$

debe ser mayor que 0. Esto es equivalente a que  $A$  sea  $T_{\arccos}$ -transitiva y la Proposición III.3 se puede reinterpretar del siguiente modo.

**Proposición IV.7.** Las siguientes afirmaciones sobre una relación borrosa reflexiva y simétrica  $R$  en un conjunto  $X$  son equivalentes.

- $R$  es tres-definida semipositiva.
- $R$  es una relación de  $T_{\arccos}$ -indistinguibilidad.
- $\sqrt{1-R}$  es una pseudodistancia en  $X$  y todo subconjunto de cardinal 3 de  $X$  se puede inyectar isométricamente en  $\mathbb{R}^3$  de tal modo que las imágenes de los puntos de  $X$  están situados en la esfera  $\mathbb{S}^2$ .

Esta última proposición también muestra la relación entre  $T_{\arccos}$  y  $T_{\sqrt{1-x}}$ . En [13] se demostró que si una relación borrosa reflexiva y simétrica es tres-definida semipositiva, entonces es  $T_{\sqrt{1-x}}$ -transitiva. Es un resultado interesante que no se sigue de forma directa de la  $T_{\arccos}$ -transitividad porque las dos t-normas no son comparables:  $T_{\arccos}(0,7,0,8) = 0,13 > 0,10 = T_{\sqrt{1-x}}(0,7,0,8)$  y  $T_{\arccos}(0,8,0,8) = 0,28 < 0,45 = T_{\sqrt{1-x}}(0,8,0,8)$ . El resultado anterior clarifica la situación.

#### IV-B. Inmersión en $\mathbb{S}^n$

Mientras que en la subsección anterior se ha obtenido la caracterización de una relación de tolerancia definida positiva  $A$  mediante el estudio de la inyectabilidad de la métrica generada por  $A$  y el generador aditivo  $t(x) = \sqrt{1-x}$  de la



t-norma  $T_{\sqrt{1-x}}$  en un espacio euclídeo, en esta subsección la caracterización se obtendrá por el estudio de la inyectabilidad de la métrica generada por el generador aditivo  $t(x) = \arccos x$  de la t-norma  $T_{\arccos}$  en una hiperesfera. Esto generaliza las interpretaciones geométricas de la Proposición III.3.

Sea  $S^n = \{\vec{v} = (x_0, x_1, \dots, x_n) \in \mathbb{R}^{n+1} \mid \sum_{i=0}^n x_i^2 = 1\}$  la hiperesfera en  $\mathbb{R}^{n+1}$  de centro el origen de coordenadas  $\vec{0}$  y radio 1. La métrica esférica  $d$  es la métrica en  $S^n$  definida para todo  $\vec{u} = (x_0, x_1, \dots, x_n), \vec{v} = (y_0, y_1, \dots, y_n) \in S^n$  por

$$d(\vec{u}, \vec{v}) = \arccos(|\sum_{i=0}^n x_i \cdot y_i|) = \arccos \langle \vec{u}, \vec{v} \rangle$$

donde  $\langle \vec{u}, \vec{v} \rangle$  es el producto escalar usual en  $\mathbb{R}^{n+1}$ . Es la longitud del mayor arco de círculo que une  $\vec{u}$  con  $\vec{v}$ .

**Proposición IV.8.** *Sea  $X = \{x_0, x_1, \dots, x_n\}$  un conjunto finito de cardinal  $n + 1$  y  $d$  una distancia en  $X$ . Denotando  $d(x_i, x_j)$  por  $d_{ij}$  para todo  $0 \leq i, j \leq n$ ,  $(X, d)$  es inyectable isométricamente en  $S^n$  si, y sólo si, la matriz  $n \times n$  con valores  $x_{ij} = \cos d_{ij}$  es definida positiva.*

En este caso, la matriz  $A$  con valores  $x_{ij}$  es la matriz de una relación borrosa reflexiva y simétrica.

El determinante de Cayley-Menger de  $d$  es

$$\begin{vmatrix} 0 & 1 & 1 & 1 & \dots & 1 \\ 1 & 0 & 1 & 1 & \dots & 1 \\ 1 & 1 & 0 & \arccos^2 x_{12} & \dots & \arccos^2 x_{1n} \\ 1 & 1 & \arccos^2 x_{12} & 0 & \dots & \arccos^2 x_{2n} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \arccos^2 x_{1n} & \arccos^2 x_{2n} & \dots & 0 \end{vmatrix}$$

Además,

$$x_{ij} = \cos d_{ij}.$$

De aquí que la siguiente proposición presenta una caracterización geométrica alternativa de las relaciones borrosas reflexivas y simétricas con la matriz asociada definida positiva.

**Proposición IV.9.** *Una relación borrosa reflexiva y simétrica  $A$  en un conjunto  $X = \{x_1, x_2, \dots, x_n\}$  finito es definida positiva si, y sólo si, es una relación de  $T_{\arccos}$ -indistinguibilidad y  $X$  con la distancia  $d(x_i, x_j) = \arccos x_{ij}$ ,  $1 \leq i, j \leq n$  se puede inyectar isométricamente en  $S^{n-1}$  con la métrica esférica.*

## V. CONCLUSIONES

En este trabajo se han dado dos caracterizaciones métricas de las relaciones borrosas reflexivas y simétricas definidas positivas mediante el uso de resultados conocidos de inyectabilidad en espacios euclídeos e hiperesferas con las distancias asociadas generadas por el generador aditivo de  $T_{\arccos}$  y  $T_{\sqrt{1-x}}$  según la Proposición II.9.

Los resultados obtenidos en la subsección IV-B permiten una elegante demostración geométrica de las Proposiciones III.8 y III.10. De forma esquemática: Es sabido que una relación de indistinguibilidad  $E$  que separe puntos en un conjunto

$X$  con  $E(x, y) \neq 0$  para todo  $x, y \in X$  transitiva respecto a una t-norma arquimediana continua determina una relación de estar entre métrica (metric betweenness relation) [6] en  $X$  que es lineal si, y sólo si,  $E$  es unidimensional [10]. En particular una relación de  $T_{\arccos}$ -indistinguibilidad unidimensional  $E$  en  $X = \{x_1, x_2, \dots, x_n\}$  determina una relación de estar entre lineal en  $X$ . Entonces  $t(E) = \arccos(E)$  es una distancia que también determina una relación de estar entre lineal en  $X$  [2] y por lo tanto los puntos de  $X$  se pueden inyectar isométricamente en un arco de una hiperesfera. Junto al centro de dicha hiperesfera determinan un  $n + 1$ -simplex contenido en un plano y por consiguiente cualquier terna de vectores  $\vec{x_0x_1}, \vec{x_0x_2}, \dots, \vec{x_0x_n}$  son linealmente dependientes. (Esto también puede interpretarse como que todos los volúmenes de este simplex de dimensión mayor que 2 son 0).

## REFERENCIAS

- [1] D. Boixader, Some Properties Concerning the Quasi-inverse of a t-norm Mathware & Soft Computing 5 (1998) 5–12.
- [2] D. Boixader, J. Recasens, Indistinguishability Operators with Respect to Different t-norms. Int. J. Uncertainty Fuzziness and Knowledge-based Systems 20 (2012) 167–183.
- [3] C. Degang, Z. Deli, Structure of feature spaces related to fuzzy similarity relations as kernels. Fuzzy Sets and Systems 237 (2014) 90–95.
- [4] L. Foulloy, E. Benoit, Building a class of fuzzy equivalence relations Fuzzy Sets and Systems 157(11) (2006) 1417–1437.
- [5] J. Jacas, On the generators of T-indistinguishability operators. Stochastica 12 (1988) 49–63.
- [6] K. Menger, Untersuchungen über allgemeine Metrik. Math. Ann. 100 (1928) 75–113.
- [7] E.P., Klement, R. Mesiar, E. Pap, Triangular norms. Kluwer Academic Publishers, Dordrecht (2000).
- [8] B. Moser, On the T-transitivity of kernels Fuzzy Sets and Systems 157(13) (2006) 1787–1796.
- [9] B. Moser, On representing and generating kernels by fuzzy equivalence relations, J. Mach. Learn. Res. 7 (2006) 2603–2620.
- [10] J. Recasens, Indistinguishability Operators. Modelling Fuzzy Equalities and Fuzzy Equivalence Relations. Studies in Fuzziness and Soft Computing. Springer, 2011.
- [11] I. J. Schoenberg, Remarks to Maurice Fréchet’s article ‘Sur la définition axiomatique d’une classe d’espace distanciés vectoriellement applicable sur l’espace de Hilbert’, Ann. Math. 36 (1935) 724–732.
- [12] P.H. Schouten, Mehrdimensionale Geometrie 2 (Die Polytope). Sammlung Schubert XXXVI, Leipzig (1905).
- [13] M.S. Tomás, C. Alsina, J. Rubio-Martinez, Pseudometrics from three-positive semidefinite similarities Fuzzy Sets and Systems 157(17) (2006) 2347–2355.
- [14] L. Valverde, On the Structure of F-indistinguishability Operators. Fuzzy Sets and Systems 17 (1985) 313–328.
- [15] L.A. Zadeh, Similarity relations and fuzzy orderings. Inform. Sci. 3 (1971) 177–200.

# Negaciones naturales asociadas a t-subnormas discretas

Sebastia Massanet<sup>\*†</sup>, Juan Vicente Riera<sup>\*†</sup>, Joan Torrens<sup>\*†</sup>

*\* Departamento de Ciencias Matemáticas e Informática*

*Grupo de investigación en Soft Computing, Procesamiento de Imágenes y Agregación (SCOPIA)*

*Universidad de las Islas Baleares, 07122 Palma, España*

*† Instituto de Investigación Sanitaria de las Islas Baleares (IdISBa), 07010 Palma, España*

*{s.massanet, jvicente.riera, jts224}@uib.es*

**Resumen**—En las últimas décadas, las operaciones definidas sobre cadenas finitas, usualmente llamadas operaciones discretas, han experimentado un gran interés por sus aplicaciones en muchos campos de la ciencia. Una de estas operaciones son las llamadas t-subnormas discretas que son una generalización de las t-normas discretas y que tienen una especial relevancia en aplicaciones que usan etiquetas lingüísticas. En este trabajo, se estudian las negaciones naturales asociadas a t-subnormas discretas incidiendo en su estructura y en algunas de sus propiedades. En particular, se caracterizan algunos casos concretos de negaciones discretas que pueden ser la negación natural asociada a una t-subnorma discreta. En este trabajo, los conceptos de negación débil y simétrica, que resultan ser equivalentes en el caso discreto, desempeñarán un papel clave.

**Index Terms**—función de agregación discreta, t-subnorma discreta, negación natural.

## I. INTRODUCCIÓN

En muchas situaciones prácticas en las que los cálculos y los razonamientos deben de ser reducidos a un número finito de posibles valores, a menudo cualitativos, el enfoque lingüístico borroso es un marco adecuado para modelar dicha información. Esto es debido, en este caso, a que los términos cualitativos usados por los expertos son habitualmente representados por variables lingüísticas en lugar de valores numéricos. En este tipo de enfoques, las variables lingüísticas se valoran en cadenas finitas totalmente ordenadas tales como:

$L = \{\text{Extremadamente Malo, Muy Malo, Malo, Regular,}$

$\text{Bueno, Muy Bueno, Extremadamente Bueno}\},$

que pueden ser todas representadas por la cadena finita  $L_n = \{0, 1, \dots, n\}$ . Consecuentemente, muchos investigadores han centrado sus esfuerzos en el estudio de operaciones definidas sobre  $L_n$ , o abreviadamente operaciones discretas (ver [7], [8], [11], [18] y concretamente [23] como trabajo pionero en este ámbito).

Entre las diferentes operaciones discretas, las funciones de agregación discretas destacan por su importancia debido a la necesidad de fusionar un conjunto inicial de datos en uno final que los represente. Existen muchos ejemplos de posibles aplicaciones de las funciones de agregación entre los que destacan los procesos de decisión, las evaluaciones subjetivas, el procesamiento de imágenes o el reconocimiento de patrones, entre otros. Por ello, el estudio de dichas funciones ha ido

en aumento en los últimos años como se evidencia con la publicación de diferentes monográficos sobre dicha temática (ver [2], [3], [12]). En muchos casos, el estudio de funciones de agregación discretas se lleva a cabo suponiendo la verificación de alguna propiedad adicional, como puede ser el caso de la suavidad, que es considerada en este entorno como la homóloga a la continuidad en el intervalo unidad, o equivalentemente la propiedad de 1-Lipschitz. En esta línea de investigación, muchas familias de funciones de agregación discretas han sido también estudiadas o incluso caracterizadas. Por ejemplo, las t-normas y t-conormas suaves han sido caracterizadas en [24] (ver también [23]), las t-subnormas suaves en [20], las medias ponderadas ordinales en [16], las uninormas en  $\mathcal{U}_{\min}$  y  $\mathcal{U}_{\max}$  y nulnormas en [18], las uninormas discretas idempotentes en [6], las uninormas y nulnormas no conmutativas en [19] y [8] respectivamente, las cópulas en [22] y las cuasi-cópulas en [1].

Las funciones de agregación discretas se pueden clasificar en cuatro grandes familias dependiendo de su relación con la función mínimo y la función máximo: conjuntivas cuando se encuentran por debajo del mínimo, disyuntivas cuando se encuentran por encima del máximo, funciones promedio o compensatorias cuando se encuentran entre el mínimo y el máximo y mixtas en cualquier otro posible caso. En este artículo, trabajaremos con funciones de agregación discretas conjuntivas y en particular, con la familia de t-subnormas discretas. Estas operaciones generalizan la familia de t-normas discretas (ver [7], [15], [24]) y pueden ser vistas como un caso particular de subgrupo topológico ordenado [5]. Las t-subnormas sobre  $[0, 1]$  juegan un papel muy relevante en la construcción de sumas ordinales de t-normas continuas por la izquierda así como en otros métodos de construcción (ver [14]). Además, los estudios sobre generadores aditivos y multiplicativos de estos operadores (ver [9], [21], [25]) así como la verificación de determinadas propiedades tales como la cancelatividad [17] o la verificación de la condición de Lipschitz justifican la importancia del estudio de las t-subnormas.

Recientemente, una línea de investigación de las t-subnormas sobre  $[0, 1]$  ha sido dedicada a su negación natural asociada. El concepto de negación natural asociada fue estudiado en [4] para el caso de t-normas continuas por la



izquierda, mientras que en [13] se investigaron en profundidad las t-subnormas con negación natural asociada fuerte. En este último trabajo, fue demostrado que tales t-subnormas son de hecho t-normas. Además se investigaron las relaciones entre diferentes propiedades algebraicas y analíticas como la cancelatividad condicional, la propiedad Arquimediana, la continuidad por la izquierda o sus elementos nilpotentes. Por ello, y siguiendo esta línea de investigación, en este artículo queremos desarrollar un estudio similar para el caso de t-subnormas discretas. La negación natural asociada a estos operadores discretos será ampliamente analizada y se presentarán varias ideas sobre su estructura.

Este trabajo se organizará de la siguiente manera: con la intención de que sea lo más autocontenido posible, en la sección II se presentaran algunos conceptos básicos sobre operaciones discretas, y en concreto sobre t-subnormas y t-normas discretas. En la sección III se estudiarán las negaciones débiles y simétricas, dos subfamilias de negaciones discretas que veremos que en el contexto discreto son equivalentes. En la sección IV, el concepto de 0-función de una t-subnorma discreta es introducido e investigado caracterizando aquellas 0-funciones que satisfacen la condición de ser una negación discreta. Además, entre otras importantes propiedades, se demuestra que las negaciones débiles son las únicas negaciones discretas que son la negación natural asociada a una t-norma discreta. Finalmente, este trabajo finaliza con la sección V en la que se exponen algunas conclusiones y posibles líneas de trabajo futuro.

## II. PRELIMINARES

Supondremos que el lector está familiarizado con los conceptos más relevantes sobre funciones de agregación, negaciones borrosas, t-normas (ver [15]) y también sobre t-normas discretas, esto es, t-normas definidas sobre una cadena finita (ver [24]). Por ello, solo recordaremos las definiciones y resultados esenciales necesarios para una correcta comprensión de este trabajo.

Es conocido (ver [24]) que para el estudio de funciones de agregación binarias todas las cadenas finitas con el mismo número de elementos son equivalentes. Por ello, utilizaremos la más simple de ellas con  $n + 1$  elementos:

$$L_n = \{0, 1, 2, \dots, n\}$$

y, para todo  $a, b \in L_n$  con  $a \leq b$ , utilizaremos la notación  $[a, b]$  para denotar la subcadena dada por  $[a, b] = \{x \in L_n \mid a \leq x \leq b\}$ .

**Definición 1 ([24]):**

- Una función  $f : L_n \rightarrow L_n$  se dice que es *suave* cuando  $|f(x) - f(x - 1)| \leq 1$  para todo  $x \in L_n$  con  $x \geq 1$ .
- Una operación binaria  $F$  sobre  $L_n$  se dice que es *suave* cuando sus secciones, vertical y horizontal, lo son.

La importancia de la condición de suavidad radica en el hecho de que generalmente esta característica es usada en el caso discreto de manera equivalente a la continuidad en el intervalo  $[0, 1]$ , propiedad equivalente a la de divisibilidad

(para una t-norma  $T$ ,  $x \leq y$  si y solo si existe  $z \in L_n$  tal que  $T(y, z) = x$ ), ver también [24].

**Proposición 2 ([24]):** La única negación suave (equivalentemente fuerte o estrictamente decreciente) sobre  $L_n$  es la negación clásica dada por

$$N(x) = n - x \quad \text{para todo } x \in L_n.$$

**Proposición 3 ([24]):** Consideremos  $m + 1$  elementos de la cadena  $L_n$  dados por  $0 = a_0 < a_1 < \dots < a_{m-1} < a_m = n$  y sea  $T_i$  una t-norma definida sobre la cadena  $[a_{i-1}, a_i]$  para todo  $i = 1, \dots, m$ . Entonces, la operación binaria sobre  $L_n$  dada por  $T(x, y) =$

$$\begin{cases} T_i(x, y) & \text{si existe un } i \text{ tal que } a_{i-1} \leq x, y \leq a_i, \\ \min\{x, y\} & \text{en otro caso,} \end{cases}$$

es siempre una t-norma en  $L_n$  usualmente llamada *suma ordinal* de las t-normas  $T_1, \dots, T_m$ .

**Proposición 4 ([24]):** Existe una y solo una t-norma Arquimediana y suave sobre  $L_n$  dada por la expresión

$$T(x, y) = \max\{0, x + y - n\} \quad (1)$$

conocida habitualmente como la t-norma de Łukasiewicz.

Además, toda t-norma suave se puede caracterizar como una suma ordinal de t-normas de Łukasiewicz del siguiente modo tal y como indica el siguiente resultado:

**Proposición 5 ([24]):** Una t-norma  $T$  sobre  $L_n$  es suave si y solo si existe un número natural  $m$  con  $1 \leq m \leq n$  y un subconjunto  $J$  de  $L_n$ ,

$$J = \{0 = a_0 < a_1 < \dots < a_{m-1} < a_m = n\}$$

tal que  $T$  viene dada por  $T(x, y) =$

$$\begin{cases} \max\{a_k, x + y - a_{k+1}\} & \text{si existe } a_k \in J \\ & \text{con } a_k \leq x, y \leq a_{k+1}, \\ \min\{x, y\} & \text{en caso contrario.} \end{cases}$$

Un concepto que generaliza la noción de t-norma es el de t-subnorma.

**Definición 6:** Sea  $T : L_n^2 \rightarrow L_n$  una operación binaria sobre  $L_n$ . Se dice que  $T$  es una *t-subnorma* cuando  $T$  es asociativa, conmutativa, creciente en cada variable y verifica  $T(x, y) \leq \min\{x, y\}$  para todo  $x, y \in L_n$ .

Obviamente, cualquier t-norma sobre  $L_n$  es también una t-subnorma pero no viceversa. Por ejemplo, la menor t-subnorma sobre  $L_n$  es la cero t-subnorma ( $T(x, y) = 0$  para todo  $x, y \in L_n$ ) que claramente no es una t-norma sobre  $L_n$ .

## III. ALGUNAS PROPIEDADES DE LA NEGACIONES DISCRETAS

Como la única negación suave sobre  $L_n$  es la clásica, expresada por  $N(x) = n - x$ , nos podemos plantear el hecho de investigar otras negaciones diferentes a ésta. En este sentido, si consideramos la posibilidad de que la negación no sea suave, podemos encontrar muchas negaciones discretas tal como veremos a continuación. Las siguientes definiciones son adaptaciones sobre  $L_n$  de las propuestas en [4] y [6].

*Definición 7:* Sea  $N : L_n \rightarrow L_n$  una negación discreta.

- $N$  es una *negación débil* si  $x \leq N^2(x)$  para todo  $x \in L_n$ .
- $N$  se dice *simétrica* cuando el conjunto

$$F_N = \{(n, 0)\} \cup \{(x, y) \in L_n^2 \mid N(x+1) \leq y \leq N(x)\}$$

es simétrico, esto es,  $(x, y) \in F_N$  si y solo si  $(y, x) \in F_N$ .

En el caso de negaciones definidas sobre el intervalo  $[0, 1]$ , las negaciones débiles y simétricas no coinciden en general, y solo coinciden en el caso en que  $N$  sea continua por la izquierda (ver [4]). El siguiente ejemplo ilustra este hecho.

*Ejemplo 8:* Las negaciones simétricas son aquellas negaciones  $N$  cuyo grafo es simétrico con respecto a la función identidad. Así, cada posible región constante de  $N$  se corresponde con un punto de discontinuidad y viceversa (ver [4]). En este sentido, si la función no es continua por la izquierda en esos puntos, la propiedad  $x \leq N^2(x)$  puede fallar. Por ejemplo, la negación dada por

$$N(x) = \begin{cases} 1 & \text{si } x \leq 0,25, \\ 1,25 - x & \text{si } 0,25 < x < 1, \\ 0 & \text{si } x = 1. \end{cases}$$

Es fácil probar que  $N$  es simétrica, pero claramente no es una negación débil ya que para todo  $x$  tal que  $0 < x \leq 0,25$  se verifica que  $N^2(x) = N(1) = 0 < x$ .

En el caso discreto ambos conceptos coinciden siempre como se verá en la siguiente proposición. La demostración de la misma es una adaptación de la considerada en el lema 2 de [6]. Hemos querido incluir la demostración de este resultado en aras de una mayor comprensión del mismo.

*Proposición 9:* Sea  $N : L_n \rightarrow L_n$  una negación discreta. Las siguientes propiedades son equivalentes:

- i)  $N$  es simétrica.
- ii)  $N$  es una negación débil.
- iii) Para todo  $(x, y) \in L_n^2$  se verifica:

$$y \leq N(x) \iff x \leq N(y).$$

*Demostración.* (i)  $\implies$  (ii). Para todo  $x \in L_n$  tenemos por definición que  $(x, N(x)) \in F_N$ . Como  $N$  es simétrica se tiene que  $(N(x), x) \in F_N$  hecho que implica que  $x \leq N(N(x))$ . Esto es,  $N$  es una negación débil.

(ii)  $\implies$  (iii). Consideremos  $(x, y) \in L_n^2$  tal que  $x \leq N(y)$ , el decrecimiento de  $N$  implica que  $N(x) \geq N(N(y)) \geq y$ . Similarmente, de  $y \leq N(x)$  se sigue que  $x \leq N(y)$ .

(iii)  $\implies$  (i). Queremos probar que  $F_N$  es simétrica. Consideremos  $(x, y) \in F_N$ , entonces  $N(x+1) \leq y \leq N(x)$  y por tanto  $x \leq N(y)$ . Por otra parte, si  $N(y+1) > x$ , entonces  $x+1 \leq N(y+1) \implies y+1 \leq N(x+1) \implies y < N(x+1)$ ,

que contradice el hecho que  $(x, y) \in F_N$ . Por tanto, concluimos que  $N(y+1) \leq x$  y así  $(y, x) \in F_N$ , demostrando que  $F_N$  es simétrica. ■

Existen muchos ejemplos de negaciones discretas débiles (o simétricas) sobre  $L_n$ . En el siguiente ejemplo presentamos

una familia paramétrica de negaciones discretas que abarcan desde la negación drástica hasta la negación clásica.

*Ejemplo 10:* Consideremos  $\alpha \in L_n$  y sea  $N_\alpha$  dada por

$$N_\alpha(x) = \begin{cases} n & \text{si } x = 0, \\ \alpha - x & \text{si } 0 < x < \alpha, \\ 0 & \text{si } x \geq \alpha. \end{cases}$$

Claramente  $N_\alpha$  es una negación débil para todo  $\alpha \in L_n$ . Además, si  $\alpha = 0$  obtenemos  $N_0$  la negación drástica, mientras que si  $\alpha = n$  obtenemos la negación clásica  $N_n(x) = n - x$ .

#### IV. T-SUBNORMAS DISCRETAS Y SUS NEGACIONES ASOCIADAS

En esta sección queremos investigar la región cero de una t-subnorma discreta similarmente a como se ha estudiado en el caso de t-subnormas definidas sobre el intervalo unidad. Para ello empezaremos dando la siguiente definición propuesta en [13] para el caso  $[0, 1]$ .

*Definición 11:* Para cada t-subnorma discreta  $T : L_n \times L_n \rightarrow L_n$ , llamaremos *0-función asociada* (denotada por  $N_T$ ) a aquella dada por

$$N_T(x) = \text{máx}\{z \in L_n \mid T(x, z) = 0\}.$$

Contrariamente a lo que ocurre para el caso de las t-normas, la 0-función asociada de una t-subnorma no necesita ser una negación discreta porque  $N_T(n) = \text{máx}\{z \in L_n \mid T(n, z) = 0\}$  podría ser diferente de 0 (cuando  $T$  es una t-subnorma propia,  $n$  no es el elemento neutro de  $T$ ). Cuando  $N_T$  sea una negación discreta, la llamaremos *negación natural asociada* de la t-subnorma  $T$ . Además, cabe destacar que

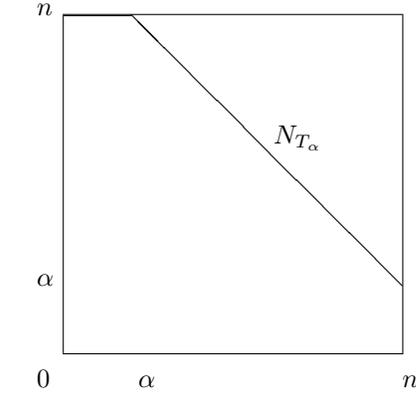
1. Si  $n = 1$ , la t-subnorma cero (con 0-función asociada dada por  $N(x) = 1$  para  $x \in \{0, 1\}$ , no es una negación), y la t-norma mínimo (con la negación clásica como negación natural asociada) son las únicas t-subnormas sobre  $L_1 = \{0, 1\}$ .

2. Cuando  $n = 2$  hay exactamente siete t-subnormas sobre  $L_2$  que pueden ser fácilmente construidas, de las cuales solo dos de ellas son t-normas. En cualquier caso, las únicas posibilidades de 0-funciones asociadas son:

- La función constante  $N(x) = 2$  para todo  $x \in L_2 = \{0, 1, 2\}$ .
- $N(x) = \begin{cases} 2 & \text{si } x \in \{0, 1\}, \\ 1 & \text{si } x = 2. \end{cases}$
- La negación clásica  $N(x) = 2 - x$ .
- La negación drástica  $N(x) = \begin{cases} 2 & \text{si } x = 0, \\ 0 & \text{si } x \in \{1, 2\}. \end{cases}$

Claramente, solo los dos últimos casos son negaciones discretas.

De acuerdo a los resultados anteriores, supondremos a partir de ahora que  $n \geq 3$ . Así, para  $n \geq 3$  podemos encontrar también ejemplos de t-subnormas, diferentes de la t-subnorma cero, cuya 0-función asociada no es una negación discreta tal como se puede ver en el siguiente ejemplo.


 Figura 1. 0-función asociada  $N_{T_\alpha}$  del ejemplo 12.

*Ejemplo 12:* Consideremos  $\alpha \in L_n$  y la función  $T_\alpha : L_n^2 \rightarrow L_n$  dada por

$$T_\alpha(x, y) = \max\{0, x + y - n - \alpha\} \quad \text{para todo } x, y \in L_n.$$

Entonces  $T_\alpha$  es siempre un t-subnorma suave (ver [20]) con  $T_\alpha(n, n) = n - \alpha$ . En particular,  $T_\alpha$  es una t-subnorma propia si y solo si  $\alpha > 0$ . Además, su 0-función asociada vendrá dada por:

$$\begin{aligned} N_{T_\alpha}(x) &= \max\{z \in L_n \mid T_\alpha(x, z) = 0\} \\ &= \max\{z \in L_n \mid x + z - n - \alpha \leq 0\}. \end{aligned}$$

Esto es,

$$N_{T_\alpha}(x) = \min\{n, n + \alpha - x\} = \begin{cases} n & \text{si } x \leq \alpha, \\ n + \alpha - x & \text{si } x > \alpha. \end{cases}$$

Por tanto, es obvio que  $N_{T_\alpha}$  es una negación discreta solo cuando  $\alpha = 0$  en cuyo caso  $T_\alpha$  es de hecho la t-norma de Łukasiewicz. Para los otros casos se tiene que  $N_{T_\alpha}(n) = \alpha > 0$ . Podemos ver dibujada la función  $N_{T_\alpha}$  en la figura 1.

En el caso discreto tenemos una fácil caracterización de las t-subnormas que verifican que  $N_T$  es una negación.

*Lema 13:* Sea  $T : L_n^2 \rightarrow L_n$  una t-subnorma discreta. La 0-función asociada a  $T$  es una negación discreta si y solo si  $T(n, 1) = 1$ .

*Demostración.* Si  $N_T$  es una negación discreta entonces  $N_T(n) = \max\{z \in L_n \mid T(x, n) = 0\} = 0$  y consecuentemente  $T(n, 1) > 0$ . Como  $T$  siempre está por debajo del mínimo entonces se debe verificar que  $T(n, 1) = 1$ .

Recíprocamente, si  $T(n, 1) = 1$  entonces  $N_T(n) = 0$  y  $N_T$  es una negación discreta. ■

Además,  $N_T$  resulta ser una negación débil y esta propiedad caracteriza de hecho las negaciones que están asociadas a una t-subnorma satisfaciendo  $T(n, 1) = 1$  (equivalentemente aquellas que están asociadas a alguna t-norma) de la siguiente manera:

*Proposición 14:* Sea  $N : L_n \rightarrow L_n$  una negación discreta. Los siguientes ítems son equivalentes:

- i) Existe una t-norma  $T$  tal que  $N = N_T$ .
- ii) Existe una t-subnorma  $T$  verificando  $T(n, 1) = 1$  tal que  $N = N_T$ .

iii)  $N$  es una negación débil.

*Demostración.* Es evidente que (i)  $\implies$  (ii). Para demostrar que (ii)  $\implies$  (iii) supongamos que existe alguna t-subnorma  $T$  con  $T(n, 1) = 1$  tal que  $N = N_T$ . En este caso tenemos  $N(x) = \max\{z \in L_n \mid T(x, z) = 0\}$  y por tanto  $T(x, N(x)) = 0$  hecho que implica directamente que

$$N^2(x) = N(N(x)) = \max\{z \in L_n \mid T(N(x), z) = 0\} \geq x.$$

Finalmente, para ver que (iii)  $\implies$  (i), consideremos  $N$  una negación débil y tomemos la función dada por

$$T(x, y) = \begin{cases} 0 & \text{si } y \leq N(x), \\ \min\{x, y\} & \text{si } y > N(x), \end{cases} \quad (2)$$

y veamos que  $T$  es una t-norma<sup>1</sup>, que tendrá claramente a  $N$  como negación natural asociada. Notar que la función  $T$  dada por la ecuación (2) es creciente en ambas variables y para todo  $x > 0$  tenemos  $T(n, x) = \min\{n, x\} = x$ , mientras que  $T(n, 0) = 0$  por definición. Así,  $T$  tiene por elemento neutro  $n$ . Como  $N$  es una negación débil, por la proposición 9 se tiene que  $y \leq N(x)$  si y solo si  $x \leq N(y)$  y esto implica que  $T$  también es conmutativa. Finalmente, es fácil ver (aunque es un cálculo tedioso) que también se verifica la propiedad asociativa y así obtenemos que  $T$  es una t-norma. ■

De acuerdo a la proposición anterior, cuando una negación discreta  $N$  es la negación asociada a alguna t-subnorma también es la negación asociada a alguna t-norma. Sin embargo, puede haber muchas más t-subnormas que t-normas que tienen una negación débil específica como su negación asociada (ver por ejemplo la proposición 17). Pero este no es el caso cuando la negación asociada sea suave, esto es, cuando se considera la negación clásica  $N(x) = n - x$  como demostraremos en el siguiente resultado, que puede ser interpretado como el homólogo para el caso discreto del teorema 3.3 de [13].

*Proposición 15:* Sea  $T : L_n^2 \rightarrow L_n$  una t-subnorma discreta con negación natural asociada  $N_T(x) = n - x$ . Entonces, necesariamente  $T$  es una t-norma.

*Demostración.* Solo es necesario ver que  $n \in L_n$  es el elemento neutro de  $T$ . Supongamos que existe un  $x \in L_n$  tal que  $T(n, x) = x' < x$ . Entonces se tiene que  $n - x' > n - x$  y consecuentemente  $T(x, n - x') > 0$ . Denotemos por  $y = T(x, n - x')$ , entonces

$$\begin{aligned} 0 &= T(n - x', x') = T(n - x', T(x, n)) \\ &= T(T(n - x', x), n) = T(y, n), \end{aligned}$$

que es una contradicción ya que por el lema 13 se tiene  $T(n, y) \geq T(n, 1) = 1$  para todo  $y > 0$ . Consecuentemente, debe ser  $T(n, x) = x$  para todo  $x \in L_n$  y por tanto  $T$  es una t-norma. ■

Como consecuencia de la proposición anterior algunos resultados conocidos para t-subnormas sobre  $[0, 1]$  que tienen una negación fuerte asociada (ver [13], [14]), pueden ser

<sup>1</sup>Para cualquier negación débil  $N$ , la t-norma  $T$  dada por la ecuación (2) es conocida habitualmente como *mínimo nülpotente* con respecto a  $N$ .

demostrados aquí para el caso discreto, tal como veremos en la siguiente proposición.

*Proposición 16:* Sea  $T : L_n^2 \rightarrow L_n$  una t-subnorma discreta con negación natural asociada  $N_T(x) = n - x$ . Las siguientes condiciones son equivalentes:

- i)  $T$  es condicionalmente cancelativa.
- ii)  $T$  es estrictamente creciente en su región positiva.
- iii)  $T$  es suave.
- iv)  $T$  es la t-norma de Łukasiewicz.

*Demostración.* Daremos solo un esbozo de la demostración. Es obvio que (i)  $\implies$  (ii).

Para demostrar que (ii)  $\implies$  (iii), consideremos  $x, y \in L_n$  con  $x < y$ . Se tiene que  $n - y < n - x$  y así,  $T(y, n - x) > 0$ . Sea  $z = T(y, n - x)$ . Entonces, usando un razonamiento similar al caso  $[0, 1]$  (ver teorema 2 de [14]) se demuestra que debe verificarse  $T(y, n - z) = x$ . Esto es, existe algún  $z \in L_n$  tal que  $T(y, z) = x$  y  $T$  satisface la propiedad de divisibilidad que es equivalente a la condición de que  $T$  sea una t-norma suave (ver la proposición 7.3.3 de [24]).

(iii)  $\implies$  (iv). Como  $T$  tiene por negación asociada  $N_T(x) = n - x$ , debe de ser una t-norma y la única t-norma suave con esta condición es la t-norma de Łukasiewicz.

Finalmente, la implicación (iv)  $\implies$  (i) es trivial. ■

La proposición 15 nos permite caracterizar todas las t-subnormas que tienen por negación natural la familia paramétrica de negaciones discretas considerada en el ejemplo 10. Para ello,

*Proposición 17:* Sea  $T : L_n^2 \rightarrow L_n$  una t-subnorma discreta. Se verifican los siguientes resultados:

- i)  $N_\alpha$  es la negación natural asociada a  $T$  si y solo si  $T$  es una suma ordinal de una t-norma  $T'$  sobre  $[0, \alpha]$  con la negación clásica  $N(x) = \alpha - x$  como negación asociada y una t-subnorma  $T''$  sobre  $[\alpha, 1]$ .
- ii) Si  $T$  es suave entonces  $N_\alpha$  es la negación natural asociada a  $T$  si y solo si  $T$  es suma ordinal de la t-norma de Łukasiewicz sobre  $[0, \alpha]$  y una t-subnorma suave  $T''$  sobre  $[\alpha, 1]$ .

*Demostración.* Probemos el primer ítem (i). Supongamos que  $N_\alpha$  es la negación natural asociada a  $T$ . Considerando la restricción de  $T$  en el cuadrado  $[0, \alpha]^2$ , claramente obtenemos una t-subnorma,  $T' = T|_{[0, \alpha]^2}$ , sobre la cadena finita  $[0, \alpha]$  con negación natural asociada  $N(x) = \alpha - x$  para todo  $x \in [0, \alpha]$ . Aplicando la proposición 15 se deduce que  $T'$  debe de ser una t-norma y consecuentemente tenemos, en particular, que  $T(\alpha, \alpha) = \alpha$ . En este caso, es bien sabido que  $T$  debe de ser una suma ordinal de una t-norma  $T'$  sobre  $[0, \alpha]$  y una t-subnorma  $T''$  sobre  $[\alpha, 1]$ .

Recíprocamente, es claro que cualquier t-subnorma expresada como una suma ordinal de una t-norma  $T'$  sobre  $[0, \alpha]$  con negación asociada  $N(x) = \alpha - x$  y una t-subnorma  $T''$  sobre  $[\alpha, 1]$ , tiene a  $N_\alpha$  como negación natural asociada.

Finalmente, notar que el ítem (ii) es consecuencia inmediata del ítem previo y de la proposición 16. ■

La estructura de las t-subnormas caracterizadas en la proposición 17 puede ser vista en la figura 2.

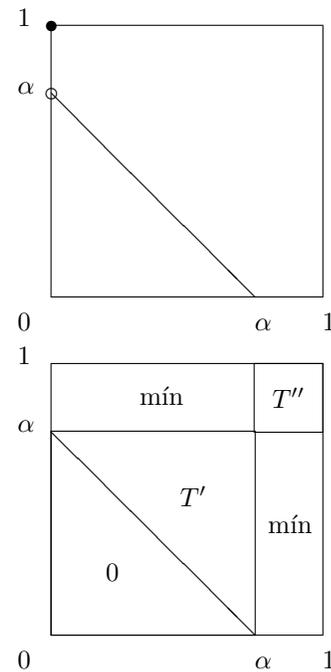


Figura 2. Negaciones  $N_\alpha$  (arriba) de la familia parametrizada dada en el ejemplo 10 y la estructura de las t-subnormas (abajo) teniendo a  $N_\alpha$  como negación natural asociada y caracterizadas en la proposición 17-(i).

## V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo, se ha presentado un estudio en profundidad sobre las negaciones naturales asociadas a t-subnormas discretas. En primer lugar, hemos demostrado la equivalencia entre negaciones débiles y negaciones simétricas en el entorno discreto, resultado que, en general, no se verifica en el intervalo unidad  $[0, 1]$  salvo que la negación borrosa sea continua por la izquierda. Después hemos introducido el concepto de 0-función de una t-subnorma discreta (a partir de la definición dada para el caso  $[0, 1]$ ) y se han caracterizado los casos en que esta función es de hecho una negación discreta. A partir de esta investigación, como consecuencia de las propiedades de sus negaciones naturales asociadas, se han demostrado varios resultados sobre la relación existente entre t-subnormas discretas y t-normas discretas. De particular importancia es la proposición 14 que demuestra que las negaciones débiles son las únicas negaciones discretas que son las negaciones naturales asociadas a una t-norma discreta.

Como trabajo futuro, queremos analizar este tema desde otra perspectiva, esto es, si fijamos una negación débil  $N$ , ¿qué t-normas  $T$  pueden ser consideradas para conseguir una nueva t-norma  $T'$  tal que  $N_{T'} = N$  y  $T'(x, y) = T(x, y)$  para todo  $y > N(x)$ ? Equivalentemente, caracterizar aquellas t-normas  $T$  cuyo operador

$$T'(x, y) = \begin{cases} 0 & \text{si } y \leq N(x), \\ T(x, y) & \text{si } y > N(x), \end{cases}$$

es una t-norma. Este problema se ha abordado ya en [4] para el caso  $[0, 1]$  pero no ha sido investigado todavía en el entorno



discreto.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente subvencionado por el proyecto TIN2016-75404-P, AEI/FEDER, UE.

#### REFERENCIAS

- [1] I. Aguiló, J. Suñer and J. Torrens, Matrix representation of discrete quasi-copulas, *Fuzzy Sets and Systems*, 159 (2008) 1658-1672.
- [2] G. Beliakov, A. Pradera and T. Calvo, *Aggregation Functions: A Guide for Practitioners*, Springer, Berlin Heidelberg (2007).
- [3] T. Calvo, G. Mayor, R. Mesiar (editors); "Aggregation operators. New trends and applications", *Studies in Fuzziness and Soft Computing*, 97. Physica-Verlag, Heidelberg, (2002).
- [4] R. Cignoli, F. Esteva, L. Godo and F. Montagna, On a class of left-continuous t-norms, *Fuzzy Sets and Systems*, 131 (2002) 283-296.
- [5] A.H. Clifford, Naturally ordered commutative semigroups, *Amer. J. Math.*, 76 (1954) 631-646.
- [6] B. De Baets, J. Fodor, D. Ruiz-Aguilera and J. Torrens, Idempotent uninorms on finite ordinal scales, *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 17 (2009) 1-14.
- [7] B. De Baets and R. Mesiar, Discrete triangular norms, in: *Topological and Algebraic Structures in Fuzzy Sets, A Handbook of Recent Developments in the Mathematics of Fuzzy Sets* (S. Rodabaugh and E.-P. Klement, eds.), *Trends in Logic* 20, Kluwer Academic Publishers, 2003, pp. 389-400.
- [8] J.C. Fodor, Smooth associative operations on finite ordinal scales, *IEEE Trans. on Fuzzy Systems*, 8 (2000) 791-795.
- [9] R. Ghiselli Ricci, Representation of continuous triangular subnorms, in *Proceedings of the IPMU-04, Perugia, Italy* (2004) pp. 1105-1110.
- [10] R. Ghiselli Ricci, R. Mesiar and A. Mesiarová, Lipschitzianity of triangular subnorms, in *Proceedings of the IMPU-06, Paris* (2006) pp. 671-677.
- [11] L. Godo and V. Torra, On aggregation operators for ordinal qualitative information, *IEEE Transactions on Fuzzy Systems*, 8 (2000) 143-154.
- [12] M. Grabisch, J.L. Marichal, R. Mesiar and E. Pap, Aggregation functions, in the series: *Encyclopedia of Mathematics and its Applications*, 127, Cambridge University Press, (2009)
- [13] B. Jayaram, T-subnorms with strong associated negation: Some properties, *Fuzzy Sets and Systems*, 323 (2017) 94-102.
- [14] S. Jenčí, Continuity of left-continuous triangular norms with strong induced negations and their boundary conditions, *Fuzzy Sets and Systems*, 124 (2001) 35-41.
- [15] E.P. Klement, R. Mesiar and E. Pap, *Triangular norms*, Kluwer Academic Publishers, Dordrecht (2000).
- [16] A. Kolesárová, G. Mayor and R. Mesiar, Weighted ordinal means, *Information Sciences*, 177 (2007) 3822-3830.
- [17] K. C. Maes, A. Mesiarová-Zemánková, Cancellativity properties for t-norms and t-subnorms, *Information Sciences*, 179 (2009) 1221-1233.
- [18] M. Mas, G. Mayor and J. Torrens, *t*-Operators and uninorms on a finite totally ordered set, *International Journal of Intelligent Systems*, 14 (1999) 909-922.
- [19] M. Mas, M. Monserrat and J. Torrens, On left and right uninorms on a finite chain, *Fuzzy Sets and Systems*, 146 (2004) 3-17.
- [20] M. Mas, M. Monserrat and J. Torrens, Smooth t-subnorms on finite scales, *Fuzzy Sets and Systems*, 167 (2011) 82-91.
- [21] G. Mayor and J. Monreal, Additive generators of discrete conjunctive aggregation operations, *IEEE Transactions on Fuzzy Systems*, 15 (2007) 1046-1052.
- [22] G. Mayor, J. Suñer and J. Torrens, Copula-like operations on finite settings, *IEEE Transactions on Fuzzy Systems*, 13 (2005) 468-477.
- [23] G. Mayor and J. Torrens, On a class of operators for expert systems, *International Journal of Intelligent Systems*, 8 (1993) 771-778.
- [24] G. Mayor and J. Torrens, Triangular norms in discrete settings, in: E.P. Klement and R. Mesiar (Eds.), *Logical, Algebraic, Analytic, and Probabilistic Aspects of Triangular Norms*. Elsevier, Amsterdam, 2005, pp. 189-230.
- [25] A. Mesiarová, Continuous triangular subnorms, *Fuzzy Sets and Systems*, 142 (2004) 75-83.

# Estudio del Modus Tollens para implicaciones borrosas

Isabel Aguiló, Jaume Suñer, Joan Torrens

*Soft Computing, Image Processing and Aggregation Research Group (SCOPIA)*

*Department of Mathematics and Computer Science*

*University of the Balearic Islands. 07122 Palma de Mallorca, Spain.*

*Balearic Islands Health Research Institute (IdISBa). 07010 Palma de Mallorca, Spain.*

isabel.aguilo@uib.es, jaume.sunyer@uib.es, jts224@uib.es

**Resumen**—En la lógica borrosa y el razonamiento aproximado, la propiedad del Modus Tollens se transforma en una desigualdad funcional involucrando una t-norma, una implicación borrosa y una negación. En este trabajo ampliamos dicha desigualdad substituyendo la t-norma por una uninorma conjuntiva, dando lugar al llamado  $U$ -Modus Tollens. Estudiamos esta nueva propiedad para implicaciones derivadas de uninormas, demostrando que existen numerosas soluciones entre las implicaciones residuadas o  $RU$ -implicaciones.

**Index Terms**—Función de implicación borrosa, Modus Tollens, uninorma, implicación residuada,  $RU$ -implicación.

## I. INTRODUCCIÓN

Las funciones de implicación borrosas se usan habitualmente, tanto para modelar los condicionales borrosos como también en el proceso de inferencia borrosa. De esta forma, la importancia de las funciones de implicación borrosas radica principalmente en sus aplicaciones que se extienden a muchos campos, y no se limitan únicamente al razonamiento aproximado y al control borroso (ver por ejemplo [3], [5], [14]). Ese es también el motivo de que resulte importante disponer de una gama de funciones de implicación borrosas tan amplia como sea posible (ver [25]), así como caracterizar aquellas que cumplen determinadas propiedades que resultan importantes en las aplicaciones.

Entre estas propiedades destacan las reglas de inferencia básicas dadas por el Modus Ponens y el Modus Tollens. En el ámbito de la lógica borrosa, dichas reglas se traducen en sendas desigualdades funcionales que se escriben respectivamente como

$$T(x, I(x, y)) \leq y \quad \text{para todos } x, y \in [0, 1], \quad (1)$$

y

$$T(N(y), I(x, y)) \leq N(x) \quad \text{para todos } x, y \in [0, 1], \quad (2)$$

donde  $T$  es una t-norma,  $I$  es una función de implicación borrosa y  $N$  una negación.

Debido a su importancia, ambas reglas de inferencia han sido extensivamente estudiadas por diversos autores (ver por ejemplo [2], [3], [12], [14], [22]–[24], [26]). Los primeros estudios se realizaron para implicaciones derivadas de t-normas y t-conormas. En concreto, las implicaciones residuadas y las  $(S, N)$ -implicaciones fueron estudiadas en [2], [22], [23] y las

QL y D-implicaciones en [24]. Como generalización de estas clases de implicaciones, se han introducido otras derivadas de uninormas, en especial las  $RU$ -implicaciones y las  $(U, N)$ -implicaciones (ver por ejemplo [1], [4], [6], [13], [18]–[20]). Recientemente, el Modus Ponens y el Modus Tollens se han estudiado también para estos dos tipos de implicaciones derivadas de uninormas (ver [12] y [11] respectivamente).

De hecho, aún cuando las uninormas se introdujeron inicialmente en el ámbito de las funciones de agregación (ver [8], [27]), también han sido estudiadas como operadores lógicos dado que siempre son conjuntivas o disyuntivas. En particular, las uninormas conjuntivas son utilizadas a menudo como conjunciones borrosas y, en este sentido, substituir en las reglas del Modus Ponens y del Modus Tollens la t-norma  $T$  por una uninorma conjuntiva  $U$  resulta natural e interesante a la vez. En esta línea, dicha substitución en el Modus Ponens fue ya considerada en [15], [16] dando lugar a la propiedad llamada  $U$ -Modus Ponens (o también  $U$ -condicionalidad). Lo primero que se deriva de estos trabajos es que las implicaciones usuales, como las derivadas de t-normas y t-conormas o las implicaciones de Yager, no satisfacen la  $U$ -condicionalidad. Así, los candidatos posibles para satisfacer el  $U$ -Modus Ponens aparecen entre las implicaciones derivadas de uninormas. Se ha estudiado y resuelto ya para el caso de  $RU$ -implicaciones en [15], [16] y se ha iniciado su estudio para el caso de  $(U, N)$ -implicaciones en [17].

Por el contrario, no se ha realizado un estudio similar para el caso del Modus Tollens. Precisamente, en este trabajo queremos rellenar ese hueco y estudiar la generalización del Modus Tollens que se obtiene substituyendo la t-norma  $T$  por una uninorma  $U$ , dando lugar a la propiedad que llamaremos  $U$ -Modus Tollens. Esto es, queremos estudiar la propiedad

$$U(N(y), I(x, y)) \leq N(x) \quad \text{para todos } x, y \in [0, 1], \quad (3)$$

donde  $U$  es una uninorma,  $I$  es una función de implicación borrosa y  $N$  una negación.

En cuanto a la organización del trabajo, tras esta introducción empezamos con un capítulo de preliminares dedicado a que el artículo sea tan autocontenido como sea posible. La sección 3 presenta la definición y primeras propiedades del Modus Tollens respecto de una uninorma  $U$ . La sección 4 estudia el  $U$ -Modus Tollens para  $RU$ -implicaciones derivadas



de tres tipos de uninormas: las de  $\mathcal{U}_{\min}$ , las representables y las idempotentes. Finalmente, la sección 5 incluye las conclusiones y algunas propuestas de trabajo futuro.

## II. PRELIMINARES

Supondremos que el lector está familiarizado con los resultados básicos sobre t-normas, t-conormas, negaciones y funciones de implicación borrosas (para detalles sobre t-normas, véase [9]; sobre implicaciones, véase [3], [5], [7]). A continuación recordaremos solo algunos conceptos sobre funciones de implicación borrosas y sobre uninormas con el objetivo de que el trabajo sea lo más autocontenido posible.

### II-A. Funciones de implicación borrosas

**Definición 1:** ([3], [7]) Una operación binaria  $I : [0, 1]^2 \rightarrow [0, 1]$  es una *función de implicación borrosa*, o una *implicación borrosa*, si satisface:

$$(I1) \quad I(x, z) \geq I(y, z) \quad \text{cuando } x \leq y, \text{ para todo } z \in [0, 1].$$

$$(I2) \quad I(x, y) \leq I(x, z) \quad \text{cuando } y \leq z, \text{ para todo } x \in [0, 1].$$

$$(I3) \quad I(0, 0) = I(1, 1) = 1 \quad \text{e} \quad I(1, 0) = 0.$$

Nótese que, de la definición, se desprende que  $I(0, x) = 1$  e  $I(x, 1) = 1$  para todo  $x \in [0, 1]$  mientras que los valores simétricos  $I(x, 0)$  e  $I(1, x)$  no se derivan de la definición.

**Definición 2:** ([3], [7]) Sea  $I$  una implicación borrosa. La función  $N_I$  definida por  $N_I(x) = I(x, 0)$  para todo  $x \in [0, 1]$ , se llama la *negación natural* de  $I$  y es siempre una negación borrosa.

A continuación recordamos algunas de las propiedades más habituales de las implicaciones borrosas que utilizaremos a lo largo del trabajo:

- El *principio de neutralidad* por la izquierda:

$$I(1, y) = y \quad \text{para todo } y \in [0, 1]. \quad (NP)$$

- El *principio de identidad*:

$$I(x, x) = 1 \quad \text{para todo } x \in [0, 1]. \quad (IP)$$

- La *contraposición* respecto de una negación  $N$ :

$$I(x, y) = I(N(y), N(x)) \quad \text{para todos } x, y \in [0, 1]. \quad CP(N)$$

### II-B. Uninormas

**Definición 3:** ([8], [27]) Una *uninorma* es una aplicación  $U : [0, 1]^2 \rightarrow [0, 1]$  asociativa, conmutativa, creciente en cada variable y tal que existe un elemento  $e \in [0, 1]$ , llamado *elemento neutro*, tal que  $U(e, x) = x$  para todo  $x \in [0, 1]$ .

Evidentemente, una uninorma con elemento neutro  $e = 1$  es una t-norma y una uninorma con elemento neutro  $e = 0$  es una t-conorma. Para cualquier otro valor  $e \in ]0, 1[$  la operación se comporta como una t-norma en  $[0, e]^2$ , como una t-conorma en  $[e, 1]^2$  y toma valores entre el mínimo y el máximo en el conjunto  $A(e)$  dado por

$$A(e) = [0, e[ \times ]e, 1] \cup ]e, 1] \times [0, e[.$$

Denotaremos de forma habitual una uninorma con elemento neutro  $e$  y t-norma y t-conorma subyacentes  $T$  y  $S$ , respectivamente, por  $U \equiv \langle T, e, S \rangle$ . Cualquier uninorma satisface que  $U(0, 1) \in \{0, 1\}$ ; cuando  $U(1, 0) = 0$ , se dice que la uninorma  $U$  es *conjuntiva*, mientras que, cuando  $U(1, 0) = 1$ , se dice que  $U$  es *disyuntiva*.

Existen muchas clases diferentes de uninormas. Las más habituales pueden hallarse en el artículo recopilatorio [10]. Recordemos aquí la estructura de tres de las clases más usadas de uninormas conjuntivas.

**Proposición 1:** ([8], [10]) Sea  $U : [0, 1]^2 \rightarrow [0, 1]$  una uninorma con elemento neutro  $e \in ]0, 1[$ . Si  $U(0, 1) = 0$ , entonces la sección  $x \mapsto U(x, 1)$  es continua excepto para  $x = e$  si y solo si  $U$  viene dada por  $U(x, y) =$

$$\begin{cases} eT\left(\frac{x}{e}, \frac{y}{e}\right) & \text{si } (x, y) \in [0, e]^2, \\ e + (1 - e)S\left(\frac{x-e}{1-e}, \frac{y-e}{1-e}\right) & \text{si } (x, y) \in [e, 1]^2, \\ \min(x, y) & \text{si } (x, y) \in A(e), \end{cases}$$

donde  $T$  es una t-norma y  $S$  es una t-conorma.

Denotaremos por  $\mathcal{U}_{\min}$  a esta clase de uninormas, y por  $U \equiv \langle T, e, S \rangle_{\min}$  a una uninorma de  $\mathcal{U}_{\min}$  con elemento neutro  $e$  y t-norma y t-conorma subyacentes  $T$  y  $S$ , respectivamente, como .

Las uninormas idempotentes fueron completamente caracterizadas para el caso general en [21] de la siguiente forma.

**Proposición 2:** ([10], [21])  $U$  es una uninorma idempotente con elemento neutro  $e \in [0, 1]$  si y solo si existe una función no creciente  $g : [0, 1] \rightarrow [0, 1]$ , simétrica respecto de la función identidad, con  $g(e) = e$ , tal que  $U(x, y) =$

$$\begin{cases} \min(x, y) & \text{si } y < g(x) \text{ o } (y = g(x) \text{ y } x < g^2(x)), \\ \max(x, y) & \text{si } y > g(x) \text{ o } (y = g(x) \text{ y } x > g^2(x)), \\ x \text{ o } y & \text{si } y = g(x) \text{ y } x = g^2(x), \end{cases}$$

y  $U$  es conmutativa en los puntos  $(x, y)$  tales que  $y = g(x)$  con  $x = g^2(x)$ .

Denotaremos por  $U \equiv \langle g, e \rangle_{\text{ide}}$  a una uninorma idempotente  $U$  con elemento neutro  $e$  y función asociada  $g$ , y a la clase de todas las uninormas idempotentes, por  $\mathcal{U}_{\text{ide}}$ .

Obviamente, para estas uninormas, la t-norma subyacente es el mínimo y la t-conorma subyacente es el máximo.

**Definición 4:** ([8], [10]) Diremos que una uninorma  $U$ , con elemento neutro  $e \in ]0, 1[$ , es *representable* si existe una función estrictamente creciente  $h : [0, 1] \rightarrow [-\infty, +\infty]$  (llamada *generador aditivo* de  $U$ , que es único excepto una constante multiplicativa  $k > 0$ ), con  $h(0) = -\infty$ ,  $h(e) = 0$  y  $h(1) = +\infty$ , tal que  $U$  viene dada por

$$U(x, y) = h^{-1}(h(x) + h(y))$$

para todos  $(x, y) \in [0, 1]^2 \setminus \{(0, 1), (1, 0)\}$ . Se tiene que  $U(0, 1) = U(1, 0) = 0$  o  $U(0, 1) = U(1, 0) = 1$ .

Denotaremos por  $U \equiv \langle e, h \rangle_{\text{rep}}$  a una uninorma representable con elemento neutro  $e \in ]0, 1[$  y generador aditivo, y a la clase de todas las uninormas representables, por  $\mathcal{U}_{\text{rep}}$ .

Por otra parte, existen diversas clases de funciones de implicación derivadas de uninormas. Recordamos aquí el caso de las  $RU$ -implicaciones.

*Definición 5:* ([6]) Sea  $U$  una uninorma. La *operación residuada* obtenida a partir de  $U$  es la operación binaria dada por

$$I_U(x, y) = \sup\{z \in [0, 1] \mid U(x, z) \leq y\}$$

para todos  $x, y \in [0, 1]$ .

*Proposición 3:* ([6]) Sea  $U$  una uninorma y  $I_U$  su operación residuada. Entonces  $I_U$  es una implicación si y sólo si  $U(x, 0) = 0$  para todo  $x < 1$ . En tal caso,  $I_U$  recibe el nombre de  *$RU$ -implicación*.

Esto incluye todas las uninormas conjuntivas, pero también muchas de disyuntivas, por ejemplo, en las clases de las uninormas representables (véase [6]) y las idempotentes (véase [18]). Sin embargo, en el caso de trabajar con uninormas continuas por la izquierda, claramente se obtiene que  $I_U$  es una implicación si y sólo si  $U$  es conjuntiva.

### III. MODUS TOLLENS RESPECTO DE UNA UNINORMA

Como ya hemos comentado el objetivo principal de este trabajo es el estudio del Modus Tollens substituyendo la  $t$ -norma  $T$  por una uninorma  $U$ , de una forma similar a como se hizo para el Modus Ponens en [15], [16]. Damos a continuación la definición formal.

*Definición 6:* Diremos que una función de implicación borrosa  $I$  y una negación  $N$  satisfacen el *Modus Tollens respecto de una uninorma  $U$* , o simplemente el  *$U$ -Modus Tollens*, si

$$U(N(y), I(x, y)) \leq N(x) \quad \text{para todos } x, y \in [0, 1]. \quad (4)$$

Notemos que la definición se ha dado para una uninorma en general y no para una que sea conjuntiva (que es el objetivo real puesto que debe generalizar la conjunción o  $t$ -norma). Esto es debido a que no es necesario dado que dicha propiedad sobre  $U$  se deriva directamente de la definición como sigue.

*Proposición 4:* Sean  $I$  una función de implicación borrosa y  $N$  una negación que satisfacen el Modus Tollens respecto de una uninorma  $U$ . Entonces la uninorma  $U$  ha de ser necesariamente conjuntiva.

De la definición resulta claro que el  $U$ -Modus Tollens no depende sólo de la uninorma y la implicación, sino también, y en especial, de la negación utilizada en la ecuación (4). Ilustramos este hecho en el siguiente ejemplo.

*Ejemplo 1:* Veamos cómo se comporta el  $U$ -Modus Tollens en los casos extremos de considerar la negación más pequeña y la más grande.

i) Consideremos la negación más pequeña  $N = N_{D_1}$  dada por

$$N_{D_1}(x) = \begin{cases} 1 & \text{si } x = 0 \\ 0 & \text{si } x > 0. \end{cases}$$

Notemos que en este caso (4) siempre se satisface para todo  $y > 0$  dado que la uninorma  $U$  es conjuntiva. Mientras que para  $y = 0$  y  $x > 0$  tenemos que

$$U(N(0), I(x, 0)) = U(1, N_I(x)) \leq N(x) = 0,$$

de donde se deduce que  $N_I(x) = 0$  para todo  $x > 0$ . En resumen, una implicación  $I$  y la negación  $N_{D_1}$  satisfacen el Modus Tollens respecto de una uninorma conjuntiva  $U$  si y sólo si  $N_I$  es la propia negación  $N_{D_1}$ .

ii) Consideremos ahora la negación más grande  $N = N_{D_2}$  dada por

$$N_{D_2}(x) = \begin{cases} 1 & \text{si } x < 1 \\ 0 & \text{si } x = 1. \end{cases}$$

En este caso se puede ver, de forma parecida, que una implicación  $I$  y la negación  $N_{D_2}$  satisfacen el Modus Tollens respecto de una uninorma conjuntiva  $U$  si y sólo si  $I(1, y) = 0$  para todo  $y < 1$ .

De forma similar al caso de  $t$ -normas, cuando la uninorma  $U$  es continua por la izquierda se puede dar una caracterización sencilla de las soluciones.

*Proposición 5:* Sean  $I$  una función de implicación borrosa,  $N$  una negación y  $U$  una uninorma conjuntiva. Si  $U$  es continua por la izquierda,  $I, N$  satisfacen el Modus Tollens respecto de  $U$  si y sólo si

$$I(x, y) \leq I_U(N(y), N(x)) \quad \text{para todos } x, y \in [0, 1],$$

donde  $I_U$  indica la implicación residuada derivada de la uninorma  $U$ .

Sin embargo, la condición anterior puede ser difícil de comprobar según los casos. Queremos estudiar con más profundidad la condición del Modus Tollens para dar resultados más específicos según sean  $U$  y  $N$ . Un primer análisis de la definición anterior permite dar algunos resultados generales que listamos en la siguiente proposición.

*Proposición 6:* Sean  $I$  una función de implicación borrosa y  $N$  una negación que satisfacen el Modus Tollens respecto de una uninorma conjuntiva  $U$ . Sea  $e$  el elemento neutro de  $U$ , entonces se satisfacen las siguientes propiedades:

1.  $U(N(y), I(1, y)) = 0$  para todo  $y \in [0, 1]$ .
2.  $N_I(x) \leq N(x)$  para todo  $x \in [0, 1]$ . Además, para todo  $x \in [0, 1]$  tal que  $N_I(x) \geq e$  ha que ser  $N(x) = 1$ .
3. Sea  $\alpha_N = \sup\{x \in [0, 1] \mid N(x) \geq e\}$ . Entonces, se satisface una y sólo una de las siguientes condiciones:
  - $N(x) < e$  para todo  $x > 0$  (es decir,  $\alpha_N = 0$ ),
  - $\alpha_N > 0$  y se tiene  $I(1, y) = 0$  para todo  $y < \alpha_N$ .
4. Si  $I$  satisface  $(NP)$ , ha de ser necesariamente  $\alpha_N = 0$ .
5. Si  $I$  satisface  $(IP)$  y  $N(x) < 1$  para todo  $x > 0$ , ha de ser necesariamente  $\alpha_N = 0$ .

A partir del apartado 3) de la proposición anterior, se deduce que si  $\alpha_N > 0$  (y eso se da por ejemplo siempre que  $N$  sea continua) las implicaciones habituales derivadas de  $t$ -normas y  $t$ -conormas ( $R$ ,  $(S, N)$ ,  $QL$  y  $D$ -implicaciones), así como las implicaciones de Yager no satisfacen nunca el  $U$ -Modus Tollens (ya que para todas ellas se satisface  $(NP)$ ). En cambio, para diversos tipos de implicaciones derivadas de uninormas, en especial las  $RU$ -implicaciones, si se tiene, o se puede tener,  $I(1, y) = 0$  para todo  $y < 1$ .

Dedicaremos por tanto la próxima sección al estudio del  $U$ -Modus Tollens para  $RU$ -implicaciones. Antes, damos algunos resultados para implicaciones en general en el caso de



negaciones con  $\alpha_N = 0$ , es decir, tales que  $N(x) < e$  para todo  $x > 0$ . El primero de ellos hace referencia a que, si  $U$  es de  $\mathcal{U}_{\min}$ , el  $U$ -Modus Tollens está garantizado para todos los valores con  $x \leq y$  y sólo hace falta verificar que se satisface para el resto de valores, es decir, para  $y < x$ .

*Proposición 7:* Sean  $I$  una función de implicación borrosa,  $N$  una negación con  $\alpha_N = 0$  y  $U$  una uninorma de  $\mathcal{U}_{\min}$  con elemento neutro  $e$ . Entonces  $I, N$  satisfacen el Modus Tollens respecto de  $U$  si y sólo si

$$U(N(y), I(x, y)) \leq N(x) \quad \text{para todos } y < x.$$

Pasamos ahora a estudiar el caso en que la implicación satisface  $(NP)$ , que es el caso de la mayoría de implicaciones derivadas de t-normas y t-conormas.

*Proposición 8:* Sean  $I$  una función de implicación borrosa que satisface  $(NP)$ ,  $N$  una negación y  $U$  una uninorma conjuntiva con elemento neutro  $e$ . Si  $I, N$  satisfacen el Modus Tollens respecto de  $U$ , entonces son ciertas las siguientes propiedades:

1.  $U(N(y), y) = 0$  para todo  $y \in [0, 1]$ .
2.  $N(x) = 0$  para todo  $x \geq e$  y  $N(x) < e$  para todo  $x > 0$ .
3.  $U(N(y), I(e, y)) = 0$  para todo  $y \in [0, 1]$ .
4. Si  $N$  es estrictamente decreciente en el intervalo  $]0, e[$ , ha de ser  $I(x, y) < e$  para todos  $y < x < e$ .

Podemos dar ahora una caracterización de las soluciones del  $U$ -Modus Tollens para el caso en que  $I$  satisfaga  $(NP)$ ,  $U$  sea de  $\mathcal{U}_{\min}$  y  $N$  sea estrictamente decreciente en el intervalo  $]0, e[$ .

*Teorema 1:* Sean  $I$  una función de implicación borrosa que satisface  $(NP)$ ,  $U \equiv \langle T_U, e, S_U \rangle_{\min}$  y  $N$  una negación estrictamente decreciente en  $]0, e[$ . Entonces  $I, N$  satisfacen el Modus Tollens respecto de  $U$ , si y sólo si se satisfacen las siguientes propiedades:

1.  $U(N(y), I(e, y)) = 0$  para todo  $y \in [0, 1]$ .
2.  $N(x) = 0$  para todo  $x \geq e$  y  $N(x) < e$  para todo  $x > 0$ .
3.  $I(x, y) < e$  para todos  $y < x < e$ .
4.  $I'$  y  $N'$  satisfacen el Modus Tollens respecto de la t-norma  $T_U$  para todos  $y < x$ , donde  $I'$  y  $N'$  vienen dadas respectivamente por

$$I'(x, y) = \begin{cases} 1 & \text{si } x \leq y \\ \frac{I(ex, ey)}{e} & \text{si } y < x \end{cases} \quad (5)$$

$$N'(x) = \begin{cases} 1 & \text{si } x = 0 \\ \frac{N(ex)}{e} & \text{en cualquier otro caso,} \end{cases} \quad (6)$$

*Ejemplo 2:* Consideremos la uninorma de  $\mathcal{U}_{\min}$ ,  $U \equiv \langle T_U, e, S_U \rangle_{\min}$  donde  $T_U = T_{LK}$  es la t-norma de Łukasiewicz y  $S_U$  es una t-conorma cualquiera. Sea  $N_e$  la negación dada por

$$N_e(x) = \begin{cases} 1 & \text{si } x = 0 \\ e - x & \text{si } 0 < x < e \\ 0 & \text{si } x \geq e. \end{cases}$$

Por último, consideremos la implicación:

$$I_e(x, y) = \begin{cases} 1 & \text{si } x = 0 \text{ o } y = 1 \\ \text{máx}(e - x, y) & \text{si } 0 < x \leq e \text{ y } 0 \leq y \leq e \\ y & \text{en cualquier otro caso.} \end{cases}$$

Es fácil ver que estos operadores satisfacen todas las condiciones del teorema 1 y por lo tanto  $I_e, N_e$  satisfacen el Modus Tollens respecto de la uninorma  $U$ .

*Nota 1:* Notemos que en el ejemplo anterior, al igual que en el teorema 1, la t-conorma  $S_U$  puede ser cualquiera y lo mismo sucede con los valores de la implicación  $I$  fuera del rectángulo  $[0, e]^2$  con la única condición de que satisfaga  $(NP)$ .

#### IV. U-MODUS TOLLENS PARA RU-IMPLICACIONES

En el apartado anterior hemos visto que si trabajamos con negaciones  $N$  con  $\alpha_N > 0$  (y esto incluye las negaciones continuas), entonces se requiere que las implicaciones satisfagan  $I(1, y) = 0$  para los valores de  $y < \alpha_N$ . Esta propiedad se satisface en  $RU$ -implicaciones derivadas, por ejemplo, de uninormas representables y también de algunas idempotentes. Por este motivo queremos estudiar en este apartado el  $U$ -Modus Tollens para  $RU$ -implicaciones. Lo haremos para  $RU$ -implicaciones derivadas de los tres tipos de uninormas conjuntivas recordados en los preliminares y lo dividiremos en una sección para cada caso.

##### IV-A. RU-implicaciones derivadas de uninormas en $\mathcal{U}_{\min}$

Veremos que en este caso tampoco son posibles negaciones continuas y volvemos a necesitar negaciones con  $\alpha_N = 0$ . En lo que sigue tomaremos  $U_0$  una uninorma de  $\mathcal{U}_{\min}$  de la forma  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$  i  $I_{U_0}$  su implicación residuada (ver [6] para detalles sobre su estructura). Entonces tenemos los siguientes resultados.

*Proposición 9:* Sea  $I_{U_0}$  la implicación borrosa derivada de una uninorma  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$ ,  $N$  una negación y  $U \equiv \langle T_U, e, S_U \rangle$  una uninorma conjuntiva. Si  $I_{U_0}, N$  satisfacen el Modus Tollens respecto de  $U$ , entonces son ciertas las siguientes propiedades:

1.  $U(N(y), y) = 0$  para todo  $y \leq e_0$ .
2.  $\alpha_N = 0$  (es decir,  $N(x) < e$  para todo  $x > 0$ ).
3.  $N(x) = 0$  para todo  $x \geq e$ .
4. Si  $e_0 < e$ ,  $T_U$  es continua y  $U(e_0, e_0) = e_0$ , se satisface  $N(x) < e_0$  para todo  $x > 0$  y  $N(x) = 0$  para todo  $x \geq e_0$ .

Para caracterizar las soluciones en este caso distinguiremos dos posibilidades según sea el orden de los elementos neutros  $e$  y  $e_0$ .

*Teorema 2:* Sea  $I_{U_0}$  la implicación borrosa derivada de una uninorma  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$ ,  $N$  una negación y  $U$  una uninorma conjuntiva con elemento neutro  $e = e_0$ . Entonces  $I_{U_0}, N$  satisfacen el Modus Tollens respecto de  $U$ , si y sólo si se satisfacen las siguientes propiedades:

1.  $N(x) = 0$  para todo  $x \geq e$  y  $N(x) < e$  para todo  $x > 0$ .

- $I_{T_0}$  y  $N'$  satisfacen el Modus Tollens respecto de la t-norma  $T_U$  para todos  $y < x$ , donde  $I_{T_0}$  es la implicación residuada derivada de la t-norma  $T_0$  y  $N'$  viene dada por la ecuación (6).

*Teorema 3:* Sea  $I_{U_0}$  la implicación borrosa derivada de una uninorma  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$ ,  $N$  una negación y  $U$  una uninorma conjuntiva con elemento neutro  $e$  con  $e < e_0$ . Supongamos que  $U_0$  viene dada por  $U_0(x, y) =$

$$\begin{cases} eT_0' \left( \frac{x}{e}, \frac{y}{e} \right) & \text{si } x, y \in [0, e] \\ e + (e_0 - e)T_0'' \left( \frac{x-e}{e_0-e}, \frac{y-e}{e_0-e} \right) & \text{si } x, y \in [e, e_0] \\ e_0 + (1 - e_0)S_0 \left( \frac{x-e_0}{1-e_0}, \frac{y-e_0}{1-e_0} \right) & \text{si } x, y \in [e_0, 1] \\ \min(x, y) & \text{en cualquier otro caso,} \end{cases}$$

siendo  $T_0', T_0''$  t-normas. Entonces  $I_{U_0}, N$  satisfacen el Modus Tollens respecto de  $U$ , si y sólo si se satisfacen las siguientes propiedades:

- $N(x) = 0$  para todo  $x \geq e$  y  $N(x) < e$  para todo  $x > 0$ .
- $I_{T_0'}$  y  $N'$  satisfacen el Modus Tollens respecto de la t-norma  $T_U$  para todos  $y < x$ , donde  $I_{T_0'}$  es la implicación residuada derivada de la t-norma  $T_0'$  y  $N'$  viene dada por la ecuación (6).

*Teorema 4:* Sea  $I_{U_0}$  la implicación borrosa derivada de una uninorma  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$ ,  $N$  una negación y  $U$  una uninorma conjuntiva con elemento neutro  $e$  con  $e_0 < e$ . Supongamos que  $U$  viene dada por  $U(x, y) =$

$$\begin{cases} e_0T_U' \left( \frac{x}{e_0}, \frac{y}{e_0} \right) & \text{si } x, y \in [0, e_0] \\ e_0 + (e - e_0)T_U'' \left( \frac{x-e_0}{e-e_0}, \frac{y-e_0}{e-e_0} \right) & \text{si } x, y \in [e_0, e] \\ e + (1 - e)S_U \left( \frac{x-e}{1-e}, \frac{y-e}{1-e} \right) & \text{si } x, y \in [e, 1] \\ \min(x, y) & \text{en cualquier otro caso,} \end{cases}$$

siendo  $T_U', T_U''$  t-normas. Entonces  $I_{U_0}, N$  satisfacen el Modus Tollens respecto de  $U$ , si y sólo si se satisfacen las siguientes propiedades:

- $N(x) = 0$  para todo  $x \geq e_0$  y  $N(x) < e_0$  para todo  $x > 0$ .
- $I_{T_0}$  y  $N'$  satisfacen el Modus Tollens respecto de la t-norma  $T_U'$  para todos  $y < x$ , donde  $I_{T_0}$  es la implicación residuada derivada de la t-norma  $T_0$  y  $N'$  viene dada por la ecuación (6).

*Nota 2:* Notemos que cuando  $U_0(e, e) = e$  y  $T_0$  es continua entonces la uninorma  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$  viene dada como en el teorema 3, ya que entonces  $T_0$  resulta ser suma ordinal de dos t-normas. Análogamente, la uninorma  $U$  viene dada como en el teorema 4 siempre que  $U(e_0, e_0) = e_0$  y  $T_U$  sea continua.

*Ejemplo 3:* En el caso  $e_0 < e$  consideremos por ejemplo uninormas  $U_0 \equiv \langle T_0, e_0, S_0 \rangle_{\min}$  y  $U$  como en el teorema 4 donde  $T_0 = T_U' = T_{LK}$  la t-norma de Łukasiewicz y  $N$  la negación dada por

$$N(x) = \begin{cases} 1 & \text{si } x = 0 \\ e_0 - x & \text{si } 0 < x < e_0 \\ 0 & \text{si } x \geq e_0. \end{cases}$$

Con estas restricciones se satisfacen las condiciones del teorema y  $I_{U_0}, N$  satisfacen el  $U$ -Modus Tollens respecto de la uninorma  $U$ .

#### IV-B. $RU$ -implicaciones derivadas de uninormas representables

No daremos en este apartado caracterizaciones generales como en el anterior, pero sí para casos concretos. En particular, veremos que en este caso sí se pueden hallar soluciones con  $\alpha_N > 0$ , incluso con negaciones fuertes. Concretamente, en este apartado  $U_0$  denotará una uninorma representable de la forma  $U_0 \equiv \langle e_0, h_0 \rangle_{\text{rep}}$  y  $I_{U_0}$  su implicación residuada (ver [3], [6] para detalles sobre su estructura). Recordemos que entonces la función

$$N_{h_0}(x) = h_0^{-1}(-h_0(x)) \quad \text{para todo } x \in [0, 1]$$

es siempre una negación fuerte que se conoce como la negación asociada a la uninorma  $U_0$ .

*Teorema 5:* Sea  $I_{U_0}$  la implicación borrosa derivada de una uninorma representable  $U_0 \equiv \langle e_0, h_0 \rangle_{\text{rep}}$ ,  $N_{h_0}$  su negación asociada y  $U$  una uninorma conjuntiva, continua por la izquierda con elemento neutro  $e$ . Entonces las siguientes condiciones son equivalentes:

- $I_{U_0}, N_{h_0}$  satisfacen el Modus Tollens respecto de  $U$ .
- $I_{U_0}(x, y) \leq I_U(N_{h_0}(y), N_{h_0}(x))$  para todos  $x, y \in [0, 1]$ .
- $U(x, y) \leq U_0(x, y)$  para todos  $x, y \in [0, 1]$ .

*Ejemplo 4:* Sea  $U_0 \equiv \langle e, h_0 \rangle_{\text{rep}}$  una uninorma representable con elemento neutro  $e \in ]0, 1[$ . Es conocido entonces que la t-norma subyacente  $T_U$  y la t-conorma  $S_U$  son estrictas. Consideremos las uninormas de  $\mathcal{U}_{\min}$  dadas por

$$U \equiv \langle T_U, e, S_U \rangle_{\min} \quad \text{y} \quad U' \equiv \langle \min, e, S_U \rangle_{\min}.$$

Es obvio que  $U \leq U_0$  pero  $U' \not\leq U_0$  y por tanto, a partir del teorema anterior, deducimos que  $I_{U_0}, N_{h_0}$  satisfacen el  $U$ -Modus Tollens respecto de  $U$  pero no respecto de  $U'$ .

#### IV-C. $RU$ -implicaciones derivadas de uninormas idempotentes

Igual que en el apartado anterior, veremos que en este caso también se pueden hallar soluciones con negaciones fuertes. Concretamente, en este apartado  $U_0$  denotará una uninorma idempotente de la forma  $U_0 \equiv \langle e_0, g_0 \rangle_{\text{ide}}$  y  $I_{U_0}$  su implicación residuada (ver [18] para detalles sobre su estructura). Recordemos que en este caso, para que  $I_{U_0}$  sea realmente una implicación, ha de ser  $g_0(0) = 1$  aunque  $U_0$  puede ser incluso disyuntiva.

*Teorema 6:* Sea  $N_0$  una negación fuerte con punto fijo  $e_0$ ,  $I_{U_0}$  la implicación borrosa derivada de una uninorma idempotente  $U_0 \equiv \langle e_0, N_0 \rangle_{\text{ide}}$  y  $U$  una uninorma conjuntiva, continua por la izquierda con elemento neutro  $e$ . Entonces las siguientes condiciones son equivalentes:

- $I_{U_0}, N_0$  satisfacen el Modus Tollens respecto de  $U$ .
- $I_{U_0}(x, y) \leq I_U(N_0(y), N_0(x))$  para todos  $x, y \in [0, 1]$ .
- $U(x, y) \leq U_0(x, y)$  para todos  $x, y \in [0, 1]$ .



## V. CONCLUSIONES Y TRABAJO FUTURO

En los procesos de inferencia borrosa resulta imprescindible utilizar conjunciones, implicaciones (y negaciones) que satisfagan el Modus Ponens y el Modus Tollens. Aún cuando generalmente las conjunciones se modelizan mediante t-normas, cada vez es más habitual introducir también el uso de uninormas conjuntivas. En este sentido, generalizar el Modus Ponens (Tollens) respecto de una de esas uninormas se convierte en un punto interesante de estudio.

De forma similar a como se hizo para el Modus Ponens en [15]–[17], en este trabajo se realiza un estudio del Modus Tollens respecto de uninormas conjuntivas. Se dan diversas propiedades necesarias para su cumplimiento y caracterizaciones de las soluciones en diversos casos concretos. Se estudia también el caso de  $RU$ -implicaciones derivadas de uninormas de  $\mathcal{U}_{\min}$ , de uninormas representables y de uninormas idempotentes.

Como trabajo futuro, quedan muchos flecos por analizar, como son un estudio más exhaustivo de los casos de  $RU$ -implicaciones derivadas de uninormas representables e idempotentes, extender dicho estudio a  $RU$ -implicaciones derivadas de otros tipos de uninormas (ver [10]) y también a  $(U, N)$ -implicaciones derivadas de uninormas (ver [3]).

### ACKNOWLEDGMENT

This paper has been partially supported by the Spanish Grant TIN2016-75404-P, AEI/FEDER, UE.

### REFERENCIAS

- [1] I. Aguiló, J. Suñer, J. Torrens, “A characterization of residual implications derived from left-continuous uninorms,” *Information Sciences*, 180, 3992–4005, 2010.
- [2] C. Alsina, E. Trillas, “When  $(S, N)$ -implications are  $(T, T_1)$ -conditional functions?,” *Fuzzy Sets and Systems*, 134, 305–310, 2003.
- [3] M. Baczyński, B. Jayaram, *Fuzzy Implications. Studies in Fuzziness and Soft Computing*, vol. 231. Springer, Berlin Heidelberg, 2008.
- [4] M. Baczyński, B. Jayaram, “ $(U, N)$ -implications and their characterizations,” *Fuzzy Sets and Systems*, 160, 2049–2062, 2009.
- [5] M. Baczyński, B. Jayaram, S. Massanet, and J. Torrens, “Fuzzy implications: Past, present, and future”, in *Springer Handbook of Computational Intelligence*, J. Kacprzyk and W. Pedrycz, Eds. Springer Berlin Heidelberg, 2015, pp. 183–202.
- [6] B. De Baets, J. C. Fodor, “Residual operators of uninorms,” *Soft Computing* 3, 89–100, 1999.
- [7] J. Fodor, M. Roubens. *Fuzzy Preference Modelling and Multicriteria Decision Support*. Kluwer Academic Publishers, Dordrecht, 1994.
- [8] J. C. Fodor, R. R. Yager, A. Rybalov, “Structure of Uninorms,” *International Journal of Uncertainty, Fuzziness and Knowledge-based Systems*, 5, 411–427, 1997.
- [9] E.P. Klement, R. Mesiar, E. Pap. *Triangular norms*. Kluwer Academic Publishers, Dordrecht, 2000.
- [10] M. Mas, S. Massanet, D. Ruiz-Aguilera, J. Torrens, “A survey on the existing classes of uninorms,” *Journal of Intelligent and Fuzzy Systems*, 29, 1021–1037, 2015.
- [11] M. Mas, J. Monreal, M. Monserrat, J.V. Riera, J. Torrens, “Modus Tollens on fuzzy implication functions derived from uninorms,” in *Fuzzy Logic and Information Fusion. To Commemorate the 70th Birthday of Professor Gaspar Mayor*. In the series: *Studies in Fuzziness and Soft Computing*, vol. 339, T. Calvo and J. Torrens, Eds. Springer, Switzerland, 2016, pp. 49–64.
- [12] M. Mas, M. Monserrat, D. Ruiz-Aguilera, J. Torrens, “ $RU$  and  $(U, N)$ -implications satisfying Modus Ponens,” *International Journal of Approximate Reasoning*, 73, 123–137, 2016.
- [13] M. Mas, M. Monserrat, J. Torrens, “Two types of implications derived from uninorms,” *Fuzzy Sets and Systems*, 158, 2612–2626, 2007.
- [14] M. Mas, M. Monserrat, J. Torrens, E. Trillas, “A survey on fuzzy implication functions,” *IEEE Transactions on Fuzzy Systems*, 15(6), 1107–1121, 2007.
- [15] M. Mas, D. Ruiz-Aguilera, J. Torrens, “On a generalization of the Modus Ponens:  $U$ -conditionality,” in *Proceedings of IPMU-2016, Part I, CCIS 610*, J.P. Carvalho et al. Eds. 2016, pp. 1–12.
- [16] M. Mas, D. Ruiz-Aguilera, J. Torrens, “On some classes of  $RU$ -implications satisfying  $U$ -Modus Ponens,” in *Aggregation functions in theory and in practice*. In the series: *Advances in Intelligent Systems and Computing*, 581, V. Torra, R. Mesiar and B. De Baets, Eds. 2018, pp. 71–82.
- [17] M. Mas, D. Ruiz-Aguilera, J. Torrens, “Generalized Modus Ponens for  $(U, N)$ -implications,” in Jesús Medina, Manuel Ojeda-Aciego, José Luis Verdegay Galdeano, David A. Pelta, Inma P. Cabrera, Bernadette Bouchon-Meunier, Ronald R. Yager (Eds.), *Proceedings of IPMU 2018, Part I, Communications in Computer and Information Science*, vol. 853 (2018) pp. 649–660.
- [18] D. Ruiz, J. Torrens, “Residual implications and co-implications from idempotent uninorms,” *Kybernetika* 40, 21–38, 2004.
- [19] D. Ruiz-Aguilera, J. Torrens, “Distributivity of residual implications over conjunctive and disjunctive uninorms,” *Fuzzy Sets and Systems*, 158, 23–37, 2007.
- [20] D. Ruiz-Aguilera, J. Torrens, “S- and R-implications from uninorms continuous in  $[0, 1]^2$  and their distributivity over uninorms,” *Fuzzy Sets and Systems*, 160, 832–852, 2009.
- [21] D. Ruiz-Aguilera, J. Torrens, B. De Baets, J. Fodor, “Some remarks on the characterization of idempotent uninorms,” in *Computational Intelligence for Knowledge-Based Systems Design. Lecture Notes in Computer Science*, vol. 6178, E. Hüllermeier, R. Kruse, F. Hoffmann, Eds. Springer, Berlin, Heidelberg, 2010, pp. 425–434.
- [22] E. Trillas, C. Alsina, A. Pradera, “On MPT-implication functions for fuzzy logic,” *Revista de la Real Academia de Ciencias. Serie A. Matemáticas (RACSAM)* 98(1), 259–271, 2004.
- [23] E. Trillas, C. Alsina, E. Renedo, A. Pradera, “On contra-symmetry and MPT-conditionality in fuzzy logic,” *International Journal of Intelligent Systems*, 20, 313–326, 2005.
- [24] E. Trillas, C. Campo, S. Cubillo, “When QM-operators are implication functions and conditional fuzzy relations,” *International Journal of Intelligent Systems*, 15, 647–655, 2000.
- [25] E. Trillas, M. Mas, M. Monserrat, J. Torrens, “On the representation of fuzzy rules,” *International Journal of Approximate Reasoning*, 48, 583–597, 2008.
- [26] E. Trillas, L. Valverde, “On Modus Ponens in fuzzy logic,” in *15th International Symposium on Multiple-Valued Logic*, pp. 294–301. Kingston, Canada, 1985.
- [27] R. R. Yager, A. Rybalov, “Uninorm aggregation operators,” *Fuzzy Sets and Systems*, 80, 111–120, 1996.

# Modus Ponens generalizado para ( $U, N$ )-implicaciones

Margarita Mas, Daniel Ruiz-Aguilera, Joan Torrens  
*Soft Computing, Procesamiento de Imágenes y Agregación (SCOPIA)*

*Departament de Ciències Matemàtiques i Informàtica  
Universitat de les Illes Balears. 07122 Palma, España.*

*Institut d'Investigació Sanitària de les Illes Balears (IdISBa). 07010 Palma, España.  
mmsg448@uib.es, daniel.ruiz@uib.es, jts224@uib.es*

**Resumen**—El Modus Ponens resulta ser una propiedad esencial en los procesos de inferencia que se llevan a cabo tanto en el razonamiento aproximado como en el control borroso. De este modo es necesario que la conjunción y la implicación borrosa utilizadas en dichos procesos de inferencia verifiquen la desigualdad inherente a la propiedad del Modus Ponens. Habitualmente la conjunción borrosa se modeliza mediante una  $t$ -norma aunque, cada vez más, se sustituye la  $t$ -norma por una uninorma conjuntiva. En este trabajo se estudia cuándo las ( $U, N$ )-implicaciones verifican el Modus Ponens respecto de una uninorma conjuntiva  $U$  en general, de forma similar a cómo se hizo para  $RU$ -implicaciones en [21], [22]. En la inecuación funcional derivada del Modus Ponens se ven involucradas dos uninormas diferentes y una negación borrosa dando lugar a diversas posibilidades. De esta manera, en esta comunicación se presenta solo un primer paso en este estudio ya que, dependiendo de las clases a las que pertenecen dichas uninormas, aparecen numerosos casos a estudiar.

**Index Terms**—Función de implicación borrosa, ( $U, N$ )-implicación, Modus Ponens,  $t$ -norma, uninorma, negación natural asociada.

## I. INTRODUCCIÓN

Las funciones de implicación borrosas se utilizan habitualmente en el razonamiento aproximado y en el control borroso para modelizar los condicionales borrosos y también para realizar inferencias. Cuando se considera la regla composicional de inferencia de Zadeh, el Modus Ponens resulta ser esencial en el proceso. Al trasladar dicha regla de inferencia al ámbito borroso se obtiene la desigualdad funcional:

$$T(x, I(x, y)) \leq y \quad \text{para todos } x, y \in [0, 1], \quad (1)$$

donde  $T$  es una  $t$ -norma continua e  $I$  es una función de implicación borrosa.

Debido a la importancia del Modus Ponens, diversos investigadores han ido realizando un estudio exhaustivo de aquellas  $t$ -normas  $T$  y funciones de implicación borrosas  $I$  que verifican la ecuación (1) a lo largo de los años (véase por ejemplo [2], [4], [17], [20], [30]–[33]). Los principales resultados en este campo se han dado para implicaciones derivadas de  $t$ -normas y  $t$ -conormas. Así, las implicaciones residuadas y las ( $S, N$ )-implicaciones se analizaron en detalle en [2], [30], [31], mientras que las QL y D-implicaciones se investigaron en [32]. Una recopilación de estos resultados y una completación de los mismos se puede hallar en la sección 7.4 del libro [4].

Sin embargo, existen otros tipos de implicaciones a considerar (véase [3], [4], [24]). Entre estos otros tipos podemos destacar las implicaciones derivadas de funciones de agregación más generales que las  $t$ -normas y las  $t$ -conormas. En particular, las implicaciones derivadas de uninormas se han estudiado de manera exhaustiva (véase por ejemplo [1], [5], [9], [18], [26]–[28]). De hecho, el Modus Ponens ha sido analizado recientemente para dos tipos concretos de implicaciones derivadas de uninormas: las  $RU$ -implicaciones y las ( $U, N$ )-implicaciones (véase [17]).

Aunque las uninormas se introdujeron inicialmente en el ámbito de las funciones de agregación (véase [11], [34]), se han estudiado también como operadores lógicos debido al hecho de que son siempre conjuntivas o disyuntivas. Dada su estructura, las uninormas se pueden ver claramente como generalizaciones de las  $t$ -normas y  $t$ -conormas simultáneamente y, en este sentido, se ha comprobado ya su utilidad en muchos campos como son los sistemas expertos borrosos (véase [10]), las redes neuronales (véase [6]) y la lógica borrosa en general (véase [25] y las referencias allí citadas). En particular, las uninormas conjuntivas se utilizan cada vez más como conjunciones borrosas y, en este sentido, sustituir en el Modus Ponens la  $t$ -norma  $T$  por una uninorma conjuntiva  $U$  resulta natural.

Siguiendo en esta línea, el caso de sustituir la  $t$ -norma  $T$  por una uninorma conjuntiva  $U$ , dando lugar al llamado  $U$ -Modus Ponens (o también  $U$ -condicionalidad), ha sido recientemente propuesto por los autores en [21], [22]. En estos trabajos se demuestra que la implicación considerada en el  $U$ -Modus Ponens tiene que verificar determinadas propiedades que son características de algunos tipos de implicaciones derivadas de uninormas: las  $RU$ -implicaciones y las ( $U, N$ )-implicaciones. En este sentido, el presente trabajo puede ser visto como una continuación de los artículos mencionados [21], [22] ya que, en estos artículos se investigó el  $U$ -Modus Ponens para el caso de las  $RU$ -implicaciones, mientras que en la presente comunicación hacemos lo mismo para el caso de las ( $U, N$ )-implicaciones.

El trabajo está organizado de la siguiente manera: tras la introducción, dedicamos la sección 2 a recordar algunos preliminares para lograr que el trabajo sea lo más autocontenido posible. La sección 3 está dedicada al Modus Ponens respecto



de una uninorma  $U$ , incluyendo algunos resultados generales para  $(U, N)$ -implicaciones. Se demuestra en particular que la uninorma disyuntiva  $U'$  utilizada para construir la  $(U, N)$ -implicación solo puede pertenecer a unas pocas clases de uninormas de entre las más usuales, a saber, las representables, las idempotentes y las continuas en  $]0, 1]^2$ . Se realiza un estudio exhaustivo para el caso de uninormas representables mientras que, para los otros dos casos, se dan simplemente diversos ejemplos. Finalmente, el trabajo concluye con la sección 4 dedicada a establecer algunas conclusiones y trabajo futuro.

## II. PRELIMINARES

Supondremos que el lector está familiarizado con los resultados básicos sobre t-normas, t-conormas y negaciones (para más detalles véase [14]). Supondremos también conocidos los resultados básicos sobre implicaciones (véase [4], [20]). A continuación recordaremos solo algunos conceptos sobre uninormas que utilizaremos a lo largo del trabajo. En cualquier caso, más detalles sobre uninormas y sus clases más estudiadas pueden hallarse en el reciente artículo recopilatorio [16].

*Definición 1:* Una uninorma es una aplicación  $U : [0, 1]^2 \rightarrow [0, 1]$  asociativa, conmutativa, creciente en cada variable y tal que existe un elemento  $e \in [0, 1]$ , llamado *elemento neutro*, tal que  $U(e, x) = x$  para todo  $x \in [0, 1]$ .

Evidentemente, una uninorma con elemento neutro  $e = 1$  es una t-norma y una uninorma con elemento neutro  $e = 0$  es una t-conorma. Para cualquier otro valor  $e \in ]0, 1[$ , la operación se comporta como una t-norma en  $[0, e]^2$ , como una t-conorma en  $[e, 1]^2$  y toma valores entre el mínimo y el máximo en el conjunto  $A(e)$  dado por

$$A(e) = [0, e[ \times ]e, 1] \cup ]e, 1] \times [0, e[.$$

Denotaremos de forma habitual una uninorma con elemento neutro  $e$  y t-norma y t-conorma subyacente,  $T$  y  $S$  respectivamente, por  $U \equiv \langle T, e, S \rangle$ . Cualquier uninorma verifica que  $U(0, 1) \in \{0, 1\}$  y cuando  $U(1, 0) = 0$  se dice que la uninorma  $U$  es *conjuntiva*, mientras que cuando  $U(1, 0) = 1$  se dice que  $U$  es *disyuntiva*. Recordemos aquí la estructura de tres de las clases más usadas de uninormas conjuntivas.

*Teorema 2:* ([11]) Sea  $U : [0, 1]^2 \rightarrow [0, 1]$  una uninorma con elemento neutro  $e \in ]0, 1[$ .

- (a) Si  $U(0, 1) = 0$ , entonces la sección  $x \mapsto U(x, 1)$  es continua excepto en  $x = e$  si y solo si  $U$  viene dada por  $U(x, y) =$

$$\begin{cases} eT\left(\frac{x}{e}, \frac{y}{e}\right) & \text{si } (x, y) \in [0, e]^2, \\ e + (1 - e)S\left(\frac{x-e}{1-e}, \frac{y-e}{1-e}\right) & \text{si } (x, y) \in [e, 1]^2, \\ \min(x, y) & \text{si } (x, y) \in A(e), \end{cases}$$

donde  $T$  es una t-norma y  $S$  es una t-conorma.

- (b) Si  $U(0, 1) = 1$ , entonces la sección  $x \mapsto U(x, 0)$  es continua excepto en  $x = e$  si y solo si  $U$  viene dada por la estructura anterior cambiando el mínimo por el máximo en  $A(e)$ .

Denotaremos por  $\mathcal{U}_{\min}$  al conjunto de uninormas de la forma dada en (a) y por  $\mathcal{U}_{\max}$  al conjunto de uninormas de la forma dada en (b). Asimismo, una uninorma de  $\mathcal{U}_{\min}$  con t-norma subyacente  $T$ , t-conorma subyacente  $S$  y elemento neutro  $e$  la denotaremos por  $U \equiv \langle T, e, S \rangle_{\min}$  y, de forma similar, a una uninorma de  $\mathcal{U}_{\max}$  la denotaremos por  $U \equiv \langle T, e, S \rangle_{\max}$ .

Las uninormas idempotentes fueron analizadas primero en [7] y posteriormente caracterizadas en [8] para el caso de tener alguna continuidad lateral, y en [15] para el caso general. El resultado definitivo fue establecido en [29] como sigue.

*Teorema 3:* ([29])  $U$  es una uninorma idempotente con elemento neutro  $e \in [0, 1]$  si y solo si existe una función decreciente  $g : [0, 1] \rightarrow [0, 1]$ , simétrica respecto de la identidad, con  $g(e) = e$  y tal que  $U(x, y) =$

$$\begin{cases} \min(x, y) & \text{si } y < g(x) \text{ o } (y = g(x) \text{ y } x < g^2(x)), \\ \max(x, y) & \text{si } y > g(x) \text{ o } (y = g(x) \text{ y } x > g^2(x)), \\ x \text{ o } y & \text{si } y = g(x) \text{ y } x = g^2(x), \end{cases}$$

siendo conmutativa en los puntos  $(x, y)$  tales que  $y = g(x)$  con  $x = g^2(x)$ .

Una uninorma idempotente  $U$  con elemento neutro  $e$  y función asociada  $g$ , la denotaremos por  $U \equiv \langle g, e \rangle_{\text{ide}}$  y la clase de todas las uninormas idempotentes la denotaremos por  $\mathcal{U}_{\text{ide}}$ . Obviamente, para esta clase de uninormas, la t-norma subyacente es siempre la t-norma mínimo y la t-conorma subyacente es siempre la t-conorma máximo.

*Definición 4:* Diremos que una uninorma  $U$  con elemento neutro  $e \in ]0, 1[$  es *representable* si existe una función estrictamente creciente  $h : [0, 1] \rightarrow [-\infty, +\infty]$  (llamada *generador aditivo* de  $U$ , que es único salvo una constante multiplicativa  $k > 0$ ), con  $h(0) = -\infty$ ,  $h(e) = 0$  y  $h(1) = +\infty$ , tal que  $U$  viene dada por

$$U(x, y) = h^{-1}(h(x) + h(y))$$

para todo  $(x, y) \in [0, 1]^2 \setminus \{(0, 1), (1, 0)\}$  y  $U(0, 1) = U(1, 0) = 0$  o  $U(0, 1) = U(1, 0) = 1$ .

Una uninorma representable con elemento neutro  $e \in ]0, 1[$  y generador aditivo  $h$  la denotaremos por  $U \equiv \langle e, h \rangle_{\text{rep}}$  y denotaremos la clase de todas las uninormas representables por  $\mathcal{U}_{\text{rep}}$ . Claramente, esta clase está contenida en la clase de uninormas continuas en  $]0, 1]^2$  que fue caracterizada en [12] (véase [16] para la versión actual y para más detalles).

*Teorema 5:* ([16]) Sea  $U$  una uninorma continua en  $]0, 1]^2$  con elemento neutro  $e \in ]0, 1[$ . Se verifica uno de los dos casos siguientes:

- (a) Existen  $u \in [0, e[$ ,  $\lambda \in [0, u[$ , dos t-normas continuas  $T_1$  y  $T_2$  y una uninorma representable  $R$  tales que  $U$  viene dada

por  $U(x, y) =$

$$\left\{ \begin{array}{ll} \lambda T_1\left(\frac{x}{\lambda}, \frac{y}{\lambda}\right) & \text{si } x, y \in [0, \lambda], \\ \lambda + (u - \lambda)T_2\left(\frac{x-\lambda}{u-\lambda}, \frac{y-\lambda}{u-\lambda}\right) & \text{si } x, y \in [\lambda, u], \\ u + (1 - u)R\left(\frac{x-u}{1-u}, \frac{y-u}{1-u}\right) & \text{si } x, y \in ]u, 1[, \\ 1 & \text{si } \min(x, y) \in ]\lambda, 1[ \\ & \text{y } \max(x, y) = 1, \\ \lambda \text{ o } 1 & \text{si } (x, y) = (\lambda, 1) \\ & \text{o } (x, y) = (1, \lambda), \\ \min(x, y) & \text{en cualquier otro caso.} \end{array} \right. \quad (2)$$

(b) Existen  $v \in ]e, 1]$ ,  $\omega \in [v, 1]$ , dos t-conormas continuas  $S_1$  y  $S_2$  y una uninorma representable  $R$  tales que  $U$  viene dada por  $U(x, y) =$

$$\left\{ \begin{array}{ll} vR\left(\frac{x}{v}, \frac{y}{v}\right) & \text{si } x, y \in ]0, v[, \\ v + (\omega - v)S_1\left(\frac{x-v}{\omega-v}, \frac{y-v}{\omega-v}\right) & \text{si } x, y \in [v, \omega[, \\ \omega + (1 - \omega)S_2\left(\frac{x-\omega}{1-\omega}, \frac{y-\omega}{1-\omega}\right) & \text{si } x, y \in [\omega, 1[, \\ 0 & \text{si } \max(x, y) \in [0, \omega[ \\ & \text{y } \min(x, y) = 0, \\ \omega \text{ o } 0 & \text{si } (x, y) = (0, \omega) \\ & \text{o } (x, y) = (\omega, 0), \\ \max(x, y) & \text{en cualquier otro caso.} \end{array} \right. \quad (3)$$

Denotaremos por  $\mathcal{U}_{\cos}^1$  la clase de todas las uninormas continuas en  $]0, 1]^2$ . La subclase formada por todas aquellas de la forma (2) la denotaremos por  $\mathcal{U}_{\cos, \min}$  y una uninorma concreta de esta clase la denotaremos por  $U \equiv \langle T_1, \lambda, T_2, u, (R, e) \rangle_{\cos, \min}$ . Análogamente, la subclase formada por las uninormas de la forma (3) será denotada por  $\mathcal{U}_{\cos, \max}$  y una uninorma concreta de esta clase la denotaremos por  $U \equiv \langle (R, e), v, S_1, \omega, S_2 \rangle_{\cos, \max}$ .

**Definición 6:** Una operación binaria  $I : [0, 1]^2 \rightarrow [0, 1]$  es una *función de implicación borrosa*, o una *implicación borrosa*, si satisface:

- (I1)  $I(x, z) \geq I(y, z)$  cuando  $x \leq y$ , para todo  $z \in [0, 1]$ .
- (I2)  $I(x, y) \leq I(x, z)$  cuando  $y \leq z$ , para todo  $x \in [0, 1]$ .
- (I3)  $I(0, 0) = I(1, 1) = 1$  e  $I(1, 0) = 0$ .

Nótese que, de la definición, se desprende que  $I(0, x) = 1$  e  $I(x, 1) = 1$  para todo  $x \in [0, 1]$  mientras que los valores simétricos  $I(x, 0)$  e  $I(1, x)$  no se derivan de la definición.

**Definición 7:** Sea  $I$  una implicación borrosa. La función  $N_I$  definida por  $N_I(x) = I(x, 0)$  para todo  $x \in [0, 1]$ , se llama la *negación natural* de  $I$  y es siempre una negación borrosa.

Por otra parte, existen diversas clases de funciones de implicación derivadas de uninormas. Recordamos aquí el caso de las  $(U, N)$ -implicaciones.

<sup>1</sup>Aquí el subíndice “cos” corresponde a las iniciales de: “continuous open square”.

**Definición 8:** Sea  $U$  una uninorma y  $N$  una negación borrosa. El  $(U, N)$ -operador derivado de  $U$  y  $N$  es la operación binaria definida por

$$I_{U, N}(x, y) = U(N(x), y) \text{ para todos } x, y \in [0, 1].$$

Es conocido que, con esta definición,  $I_{U, N}$  es una función de implicación borrosa si y solo si  $U$  es disyuntiva y entonces se conoce con el nombre de  $(U, N)$ -implicación. Algunas propiedades de las  $(U, N)$ -implicaciones han sido estudiadas para diversos tipos de uninormas entre las que destacan las ya recordadas en estos preliminares, pero también otras como las uninormas *localmente internas* o *compensatorias* y las uninormas con operadores subyacentes continuos (para más detalles véase [4], [5], [17], [19], [28]). Recientemente, el Modus Ponens respecto de una t-norma  $T$  se ha estudiado en detalle en [17] para implicaciones derivadas de uninormas.

### III. $U$ -MODUS PONENS PARA $(U, N)$ -IMPLICACIONES

En esta sección queremos estudiar el Modus Ponens respecto de una uninorma  $U$ , o simplemente el  $U$ -Modus Ponens, para la clase de las  $(U, N)$ -implicaciones. Empezamos estableciendo de manera formal la definición del  $U$ -Modus Ponens.

**Definición 9:** Sea  $I$  una implicación borrosa y  $U$  una uninorma. Diremos que  $I$  verifica el *Modus Ponens* respecto de  $U$  (o simplemente el  $U$ -Modus Ponens), o también que  $I$  es un  $U$ -condicional si

$$U(x, I(x, y)) \leq y \text{ para todos } x, y \in [0, 1]. \quad (4)$$

Nuestra intención es estudiar la desigualdad anterior en el caso en que la implicación  $I$  sea una  $(U, N)$ -implicación. Es ya conocido (véase [21]) que si  $I$  y  $U$  verifican la inecuación (4),  $U$  tiene que ser necesariamente conjuntiva. Por lo tanto, en todo lo que sigue, consideraremos que  $U$  es una uninorma conjuntiva,  $U'$  es una uninorma disyuntiva y  $N$  una negación borrosa a partir de las cuales derivamos la  $(U, N)$ -implicación  $I_{U', N}$ . Damos primero algunas propiedades necesarias para que se verifique el  $U$ -Modus Ponens.

**Proposición 10:** Sea  $U$  una uninorma conjuntiva con elemento neutro  $e \in ]0, 1[$  y  $U'$  una uninorma disyuntiva con elemento neutro  $e' \in ]0, 1[$ . Sea  $N$  una negación borrosa y sea  $I_{U', N}$  la correspondiente  $(U, N)$ -implicación. Si  $I_{U', N}$  verifica el  $U$ -Modus Ponens respecto de  $U$ , se verifican las siguientes propiedades:

- i)  $U'(N(e), y) \leq y$  para todo  $y \in [0, 1]$ . En particular, se tiene que cumplir  $N(e) \leq e'$ .
- ii)  $U'(N(x), y) \leq e$  para todos  $x, y$  tales que  $e \leq y < x$ . En particular, se tiene que cumplir  $U'(0, y) < e$  para todo  $y$  tal que  $e \leq y < 1$ .
- iii)  $U(x, N(x)) \leq e'$  para todo  $x \in [0, 1]$ . En particular, si  $N$  tiene  $e_N$  como punto fijo, entonces  $U(e_N, e_N) \leq e'$ .
- iv) La negación borrosa  $N$  verifica  $N(x) < 1$  para todo  $x > 0$ .

La proposición anterior muestra algunas condiciones necesarias sobre las uninormas  $U$ ,  $U'$  y sobre la negación  $N$  para que la correspondiente  $I_{U', N}$  verifique el  $U$ -Modus Ponens. A



partir de ahora, nos restringiremos al caso en que la uninorma  $U'$  es localmente interna en la frontera, esto es,  $U'$  verifica  $U'(0, y) \in \{0, y\}$  para todo  $y > e'$  (véase [13], [16]). Notemos sin embargo que esta condición no es en absoluto restrictiva ya que todas las clases habituales de uninormas son localmente internas en la frontera. Eso incluye, no solo las clases recordadas en los preliminares, sino también las localmente internas y las uninormas con operadores subyacentes continuos (véase [16]).

El siguiente resultado actualiza la proposición anterior en el caso en que la uninorma  $U'$  sea localmente interna en la frontera.

*Proposición 11:* Sea  $U$  una uninorma conjuntiva con elemento neutro  $e \in ]0, 1[$  y  $U'$  una uninorma disyuntiva, localmente interna en la frontera, con elemento neutro  $e' \in ]0, 1[$ . Sea  $N$  una negación continua y sea  $I_{U',N}$  la correspondiente  $(U, N)$ -implicación. Si  $I_{U',N}$  verifica el  $U$ -Modus Ponens respecto de  $U$  entonces:

- Se tiene que cumplir  $U'(0, y) = 0$  para todo  $y < 1$ .
- La negación natural asociada a  $I_{U',N}$  tiene que ser la negación drástica  $N_D$  dada por  $N_D(x) = 0$  para todo  $x > 0$ .
- $U'$  no puede ser de  $\mathcal{U}_{m\acute{a}x}$ .
- Si  $U'$  es de  $\mathcal{U}_{cos,m\acute{a}x}$ , digamos  $U' \equiv \langle (R, e'), v, S_1, \omega, S_2 \rangle_{cos,m\acute{a}x}$ , entonces se tiene que cumplir  $\omega = 1$ .
- Si  $U'$  es idempotente, digamos  $U' \equiv \langle g', e' \rangle_{ide}$ , entonces se tiene que cumplir  $g'(0) = 1$ .

*Nota 12:* A partir de la proposición anterior tenemos que la uninorma disyuntiva  $U'$  usada en la construcción de  $I_{U',N}$  no puede ser cualquiera. Sin embargo, notemos que aún quedan otras posibilidades de entre las clases de uninormas consideradas en los preliminares. Concretamente,  $U'$  puede ser de cualesquiera de las siguientes clases:

- uninormas representables, o
- uninormas idempotentes con  $g'(0) = 1$ , o
- uninormas de  $\mathcal{U}_{cos,m\acute{a}x}$  con  $\omega = 1$ , o
- uninormas de  $\mathcal{U}_{cos,m\acute{m}n}$  con  $\lambda = 0$  ( $\lambda = 0$  es necesario para asegurar que la uninorma  $U'$  sea disyuntiva).

Antes de tratar con cada una de estas clases de forma separada presentamos en esta sección algunos resultados generales adicionales.

Obviamente la  $(U, N)$ -implicación  $I_{U',N}$  depende completamente no solo de la uninorma  $U'$ , sino también de la negación  $N$  usada en su construcción. Recordemos que ya hemos visto que la negación  $N$  no puede tomar el valor 1 en puntos  $x > 0$  si queremos que se verifique el  $U$ -Modus Ponens. Por el contrario,  $N$  puede tomar el valor 0 en subintervalos no triviales como indica la siguiente proposición.

*Proposición 13:* Sea  $U'$  una uninorma disyuntiva en alguna de las clases descritas en la nota 12. Si  $N = N_D$  es la negación borrosa drástica, entonces  $I_{U',N}$  viene dada por la menor implicación borrosa posible

$$I_{U',N}(x, y) = I_0(x, y) = \begin{cases} 1 & \text{si } x = 0 \text{ o } y = 1, \\ 0 & \text{en cualquier otro caso,} \end{cases}$$

que verifica siempre el  $U$ -Modus Ponens respecto de cualquier uninorma conjuntiva  $U$ .

En lo que queda de sección vamos a considerar solo el caso en que la negación  $N$  sea al menos continua, que es en realidad el caso más habitual<sup>2</sup>. En esta situación, vemos que también se puede descartar la clase de uninormas de  $\mathcal{U}_{cos,m\acute{a}x}$ .

*Proposición 14:* Sea  $U$  una uninorma conjuntiva con elemento neutro  $e \in ]0, 1[$  y  $U'$  una uninorma disyuntiva con elemento neutro  $e' \in ]0, 1[$ . Sea  $N$  una negación continua y sea  $I_{U',N}$  la correspondiente  $(U, N)$ -implicación. Si  $I_{U',N}$  verifica el  $U$ -Modus Ponens respecto de  $U$  entonces  $U'$  no puede ser de  $\mathcal{U}_{cos,m\acute{a}x}$ .

Recordemos que cuando la negación borrosa considerada  $N$  es continua ha de tener un punto fijo que denotaremos por  $e_N$ . En este caso tenemos hasta tres valores clave en nuestro estudio. A saber, los elementos neutros de  $U, U'$  y el punto fijo de  $N$ , es decir,  $e, e'$  y  $e_N$  respectivamente. La siguiente proposición establece la relación de orden posible entre los mismos según los casos.

*Proposición 15:* Sea  $U$  una uninorma conjuntiva con elemento neutro  $e \in ]0, 1[$  y  $U'$  una uninorma disyuntiva con elemento neutro  $e' \in ]0, 1[$ . Sea  $N$  una negación continua con punto fijo  $e_N$  y sea  $I_{U',N}$  la correspondiente  $(U, N)$ -implicación. Si  $I_{U',N}$  verifica el  $U$ -Modus Ponens respecto de  $U$  entonces,

- Si  $e' < e_N$ , necesariamente se tiene que cumplir  $e' < e_N < e, y$
- Si  $e' = e_N$ , necesariamente se tiene que cumplir  $e' = e_N \leq e$ .

Notemos que el caso  $e' > e_N$  no está incluido en la proposición anterior. Ello es debido a que en dicho caso, no hay restricciones iniciales para la posición de  $e$  con respecto a los valores  $e' > e_N$ .

El siguiente paso en nuestra investigación será realizar un estudio del  $U$ -Modus Ponens para  $(U, N)$ -implicaciones derivadas de uninormas de cada una de las clases posibles teniendo en cuenta los resultados anteriores. Esto es, un caso para  $(U, N)$ -implicaciones derivadas de uninormas representables disyuntivas  $U'$ , otro para las derivadas de uninormas  $U'$  de  $\mathcal{U}_{cos,m\acute{m}n}$  con  $\lambda = 0$  y otro para las derivadas de uninormas idempotentes  $U'$  con  $g'(0) = 1$ .

### III-A. Caso en el que $U'$ es una uninorma representable

Vamos a tratar en esta sección con uninormas disyuntivas representables del tipo  $U' \equiv \langle e', h' \rangle_{rep}$ . En este caso la correspondiente  $(U, N)$ -implicación derivada de  $U'$  y la negación  $N$  viene dada por

$$I_{U',N}(x, y) = h'^{-1}(h'(N(x)) + h'(y))$$

para todos  $x, y \in [0, 1]$ , con el convenio  $+\infty - \infty = +\infty$ . Recordemos también que, a partir de una uninorma representable disyuntiva  $U' \equiv \langle e', h' \rangle_{rep}$ , se obtiene la negación

<sup>2</sup>Recordemos que las negaciones continuas son las más utilizadas en lógica borrosa y que contienen, en particular, a las negaciones fuertes (aquellas que son involutivas) y también a las estrictas (aquellas que son estrictamente decrecientes y continuas).

fuerte  $N_{h'}(x) = h'^{-1}(-h'(x))$  para todo  $x \in [0, 1]$ , que es usualmente conocida como la negación fuerte asociada a  $U'$ .

Teniendo en cuenta estas consideraciones, se pueden obtener en este caso los siguientes resultados parciales.

*Proposición 16:* Sea  $U$  una uninorma conjuntiva con elemento neutro  $e \in ]0, 1[$ ,  $U' \equiv \langle e', h' \rangle_{\text{rep}}$  disyuntiva,  $N$  una negación borrosa e  $I_{U', N}$  la correspondiente  $(U, N)$ -implicación. Si  $U \leq U'$  y  $N \leq N_{h'}$ , entonces  $I_{U', N}$  verifica el  $U$ -Modus Ponens respecto de  $U$ .

En el caso en que la negación considerada  $N$  coincida con la negación fuerte asociada  $N_{h'}$ , la condición  $U \leq U'$  se convierte en necesaria y suficiente como se ve en el siguiente resultado.

*Proposición 17:* Sea  $U$  una uninorma conjuntiva con elemento neutro  $e \in ]0, 1[$ ,  $U' \equiv \langle e', h' \rangle_{\text{rep}}$  disyuntiva,  $N = N_{h'}$  la negación fuerte asociada a  $U'$  e  $I_{U', N}$  la correspondiente  $(U, N)$ -implicación. Entonces  $I_{U', N}$  verifica el  $U$ -Modus Ponens respecto de  $U$  si y solo si  $U \leq U'$ .

Damos a continuación algunos ejemplos de  $(U, N)$ -implicaciones, basadas en uninormas disyuntivas representables, que verifican el  $U$ -Modus Ponens.

*Ejemplo 18:* A partir de resultados anteriores podemos presentar los siguientes ejemplos de  $(U, N)$ -implicaciones que verifican el  $U$ -Modus Ponens.

- i) Sea  $U' \equiv \langle e', h' \rangle_{\text{rep}}$  una uninorma representable disyuntiva con elemento neutro  $e' \in ]0, 1[$  y  $N = N_{h'}$  la negación fuerte asociada a  $U'$ . En estos casos, es sabido que la  $t$ -norma  $T_{U'}$  y la  $t$ -conorma  $S_{U'}$  subyacentes son estrictas. Consideremos entonces las uninormas de  $\mathcal{U}_{\text{mín}}$  dadas por

$$U_0 \equiv \langle T_{U'}, e', S_{U'} \rangle_{\text{mín}} \quad \text{y} \quad U_1 \equiv \langle \text{mín}, e', S_{U'} \rangle_{\text{mín}},$$

donde  $S_{U'}$  es cualquier  $t$ -conorma. Entonces resulta claro que  $U_0 \leq U'$  pero en cambio  $U_1 \not\leq U'$ . De esta manera, a partir de la proposición 17, tenemos que  $I_{U', N}$  verifica el  $U$ -Modus Ponens respecto de  $U_0$  pero no lo verifica respecto de  $U_1$ .

- ii) Tomemos en este caso la uninorma dada por  $U'(x, y) =$

$$\begin{cases} 1 & \text{si } (x, y) \in \{(1, 0), (0, 1)\}, \\ \frac{xy}{(1-x)(1-y)+xy} & \text{en cualquier otro caso.} \end{cases}$$

Se sabe que  $U'$  es una uninorma disyuntiva representable con elemento neutro  $e' = \frac{1}{2}$  y generador aditivo  $h'(x) = \log\left(\frac{x}{1-x}\right)$  (ver [11]). Más aún, su negación asociada es la negación clásica  $N_c(x) = 1 - x$ . De este modo, si tomamos la uninorma de  $\mathcal{U}_{\text{mín}}$  dada por  $U(x, y) =$

$$\begin{cases} 2xy & \text{si } x, y \leq 1/2, \\ 2x + 2y - 2xy - 1 & \text{si } x, y \geq 1/2, \\ \text{mín}(x, y) & \text{en cualquier otro caso,} \end{cases}$$

podemos ver fácilmente que  $U \leq U'$  y, considerando cualquier negación borrosa  $N$  tal que  $N \leq N_c$ , la correspondiente  $(U, N)$ -implicación  $I_{U', N}$  verifica el  $U$ -Modus Ponens respecto de  $U$  (aplicando simplemente la proposición 16).

Precisamente, debido a las restricciones de espacio, en las secciones siguientes nos limitaremos a dar sendos ejemplos de  $(U, N)$ -implicaciones verificando el  $U$ -Modus Ponens, basadas en uninormas disyuntivas pertenecientes a la clase correspondiente. Dejaremos en cambio el estudio exhaustivo de estos casos para un trabajo futuro.

*III-B. Caso en el que  $U'$  es una uninorma de  $\mathcal{U}_{\text{cos, mín}}$  con  $\lambda = 0$*

Damos en este caso el siguiente ejemplo que demuestra la existencia de numerosas  $(U, N)$ -implicaciones verificando el  $U$ -Modus Ponens basadas en uninormas disyuntivas de  $\mathcal{U}_{\text{cos, mín}}$  con  $\lambda = 0$ .

*Ejemplo 19:* Consideremos  $U'$  una uninorma disyuntiva de  $\mathcal{U}_{\text{cos, mín}}$  con  $\lambda = 0$ , digamos  $U' \equiv \langle 0, T, u, (R, e') \rangle_{\text{cos, mín}}$ . Consideremos cualquier uninorma  $U$  de  $\mathcal{U}_{\text{mín}}$  con elemento neutro  $e = u$  cualquier negación borrosa continua  $N$  con punto fijo  $e_N = u$  y tal que  $N(x) < 1$  para todo  $x > 0$ . Entonces, la  $(U, N)$ -implicación derivada de  $U'$  y de  $N$  verifica siempre el  $U$ -Modus Ponens respecto de  $U$ .

*III-C. Caso en el que  $U'$  es una uninorma idempotente con  $g(0) = 1$*

El siguiente ejemplo muestra que existen numerosas  $(U, N)$ -implicaciones que verifican el  $U$ -Modus Ponens, en este caso basadas en uninormas idempotentes disyuntivas con  $g(0) = 1$ .

*Ejemplo 20:* Consideremos una negación fuerte  $N$  con punto fijo  $e \in ]0, 1[$  y sean  $U$  y  $U'$  las uninormas idempotentes dadas respectivamente por:

$$U(x, y) = \begin{cases} \text{mín}(x, y) & \text{si } y \leq N(x), \\ \text{máx}(x, y) & \text{si } y > N(x), \end{cases}$$

y

$$U'(x, y) = \begin{cases} \text{mín}(x, y) & \text{si } y < N(x), \\ \text{máx}(x, y) & \text{si } y \geq N(x). \end{cases}$$

Claramente tenemos que  $U$  es conjuntiva,  $U'$  es disyuntiva y la  $(U, N)$ -implicación derivada de  $U'$  y  $N$  verifica el  $U$ -Modus Ponens respecto de  $U$ .

#### IV. CONCLUSIONES Y TRABAJO FUTURO

El Modus Ponens es la regla borrosa básica comúnmente utilizada en el razonamiento aproximado y el control borroso para manejar inferencias borrosas. De este modo, es lógico requerir a la conjunción y a la implicación borrosas que se vayan a usar en los procesos de inferencia, que verifiquen la inecuación funcional asociada al Modus Ponens. Habitualmente, se usa una  $t$ -norma para modelizar la conjunción borrosa pero, cada vez más, se utiliza también una uninorma conjuntiva en su lugar, lo que nos lleva a considerar el llamado  $U$ -Modus Ponens.

Dicha propiedad ya ha sido estudiada para implicaciones residuadas derivadas de uninormas ( $RU$ -implicaciones) en [21], [22]. Siguiendo en la misma línea, en este trabajo hemos iniciado el estudio para  $(U, N)$ -implicaciones, es decir para



implicaciones derivadas de uninormas disyuntivas y negaciones borrosas. Hemos visto que, de entre las clases de uninormas disyuntivas más habituales, solo existen soluciones en los casos de  $(U, N)$ -implicaciones derivadas de uninormas representables, de uninormas en  $\mathcal{U}_{\cos, \min}$  con  $\lambda = 0$  y de uninormas idempotentes con  $g(0) = 1$ . Hemos dado ejemplos en cada uno de los tres casos, aunque, mientras que el caso relativo a uninormas representables ha sido resuelto con detalle, un estudio exhaustivo de los otros dos casos se ha dejado para un trabajo futuro.

Queremos especificar que como trabajo futuro, además del ya mencionado, pretendemos extender nuestro estudio a otros tipos de implicaciones como son las  $h$  y  $(h, e)$ -implicaciones recientemente introducidas en [23]. Finalmente, es nuestra intención desarrollar también un estudio similar de una generalización mediante uninormas de la regla de inferencia del Modus Tollens.

*Agradecimientos:* Este trabajo ha sido parcialmente subvencionado por el proyecto TIN2016- 75404-P AEI/FEDER, UE.

#### REFERENCIAS

- [1] I. Aguiló, J. Suñer, J. Torrens, "A characterization of residual implications derived from left-continuous uninorms," *Information Sciences*, 180, 3992–4005, 2010.
- [2] C. Alsina, E. Trillas, "When  $(S, N)$ -implications are  $(T, T_1)$ -conditional functions?," *Fuzzy Sets and Systems*, 134, 305–310, 2003.
- [3] M. Baczyński, G. Beliakov, H. Bustince Sola, A. Pradera, Eds., *Advances in Fuzzy Implication Functions, in Studies in Fuzziness and Soft Computing*, vol. 300, Springer, Berlin Heidelberg, 2013.
- [4] M. Baczyński, B. Jayaram, *Fuzzy Implications. Studies in Fuzziness and Soft Computing*, vol. 231. Springer, Berlin Heidelberg, 2008.
- [5] M. Baczyński, B. Jayaram, "(U,N)-implications and their characterizations," *Fuzzy Sets and Systems*, 160, 2049–2062, 2009.
- [6] J.M. Benítez, J.L. Castro, I. Requena, "Are artificial neural networks black boxes?," *IEEE Transactions on Neural Networks* 8, 1156–1163, 1997.
- [7] E. Czogala, J. Drewniak, "Associative monotonic operations in fuzzy set theory," *Fuzzy Sets and Systems* 12, 249–269, 1984.
- [8] B. De Baets, "Idempotent uninorms," *European Journal of Operational Research* 118, 631–642, 1999.
- [9] B. De Baets, J. C. Fodor, "Residual operators of uninorms," *Soft Computing* 3, 89–100, 1999.
- [10] B. De Baets, J. Fodor, "Van Melle's combining function in MYCIN is a representable uninorm: an alternative proof," *Fuzzy Sets and Systems* 104, 133–136, 1999.
- [11] J. C. Fodor, R. R. Yager, A. Rybalov, "Structure of Uninorms," *International Journal of Uncertainty, Fuzziness and Knowledge-based Systems*, 5, 411–427, 1997.
- [12] S. Hu, Z. Li, "The structure of continuous uni-norms," *Fuzzy Sets and Systems* 124, 43–52, 2001.
- [13] G. Li, H.W. Liu, "On properties of uninorms locally internal on the boundary," *Fuzzy Sets and Systems* 332, 116–128, 2018.
- [14] E.P. Klement, R. Mesiar, E. Pap. *Triangular norms*. Kluwer Academic Publishers, Dordrecht, 2000.
- [15] J. Martín, G. Mayor, J. Torrens, "On locally internal monotonic operators," *Fuzzy Sets and Systems* 137, 27–42, 2003.
- [16] M. Mas, S. Massanet, D. Ruiz-Aguilera, J. Torrens, "A survey on the existing classes of uninorms," *Journal of Intelligent and Fuzzy Systems*, 29, 1021–1037, 2015.
- [17] M. Mas, M. Monserrat, D. Ruiz-Aguilera, J. Torrens, " $RU$  and  $(U, N)$ -implications satisfying Modus Ponens," *International Journal of Approximate Reasoning*, 73, 123–137, 2016.
- [18] M. Mas, M. Monserrat, J. Torrens, "Two types of implications derived from uninorms," *Fuzzy Sets and Systems*, 158, 2612–2626, 2007.
- [19] M. Mas, M. Monserrat, J. Torrens, "A characterization of  $(U, N)$ ,  $RU$ ,  $QL$  and  $D$ -implications derived from uninorms satisfying the law of importation," *Fuzzy Sets and Systems* 161, 1369–1387, 2010.
- [20] M. Mas, M. Monserrat, J. Torrens, E. Trillas, "A survey on fuzzy implication functions," *IEEE Transactions on Fuzzy Systems*, 15(6), 1107–1121, 2007.
- [21] M. Mas, D. Ruiz-Aguilera, J. Torrens, "On a generalization of the Modus Ponens:  $U$ -conditionality," in *Proceedings of IPMU-2016, Part I, CCIS 610*, J.P. Carvalho et al. Eds. 2016, pp. 1–12.
- [22] M. Mas, D. Ruiz-Aguilera, J. Torrens, "On some classes of  $RU$ -implications satisfying  $U$ -Modus Ponens," in *Aggregation functions in theory and in practice. In the series: Advances in Intelligent Systems and Computing*, 581, V. Torra, R. Mesiar and B. De Baets, Eds. 2018, pp. 71–82.
- [23] S. Massanet, J. Torrens, "On a new class of fuzzy implications:  $h$ -implications and generalizations," *Information Science* 181, 2111–2127, 2011.
- [24] S. Massanet, J. Torrens, "An overview of construction methods of fuzzy implications," in [3], pp. 1–30, 2013.
- [25] G. Metcalfe, F. Montagna, "Substructural Fuzzy Logics," *The Journal of Symbolic Logic* 72, 834–864, 2007.
- [26] D. Ruiz, J. Torrens, "Residual implications and co-implications from idempotent uninorms," *Kybernetika* 40, 21–38, 2004.
- [27] D. Ruiz-Aguilera, J. Torrens, "Distributivity of residual implications over conjunctive and disjunctive uninorms," *Fuzzy Sets and Systems*, 158, 23–37, 2007.
- [28] D. Ruiz-Aguilera, J. Torrens, "S- and R-implications from uninorms continuous in  $]0, 1[$  and their distributivity over uninorms," *Fuzzy Sets and Systems*, 160, 832–852, 2009.
- [29] D. Ruiz-Aguilera, J. Torrens, B. De Baets, J. Fodor, "Some remarks on the characterization of idempotent uninorms," in *Computational Intelligence for Knowledge-Based Systems Design. Lecture Notes in Computer Science*, vol. 6178, E. Hillermeier, R. Kruse, F. Hoffmann, Eds. Springer, Berlin, Heidelberg, 2010, pp. 425–434.
- [30] E. Trillas, C. Alsina, A. Pradera, "On MPT-implication functions for fuzzy logic," *Revista de la Real Academia de Ciencias. Serie A. Matemáticas (RACSAM)* 98(1), 259–271, 2004.
- [31] E. Trillas, C. Alsina, E. Renedo, A. Pradera, "On contra-symmetry and MPT-conditionality in fuzzy logic," *International Journal of Intelligent Systems*, 20, 313–326, 2005.
- [32] E. Trillas, C. Campo, S. Cubillo, "When QM-operators are implication functions and conditional fuzzy relations," *International Journal of Intelligent Systems*, 15, 647–655, 2000.
- [33] E. Trillas, L. Valverde, "On Modus Ponens in fuzzy logic," in *15th International Symposium on Multiple-Valued Logic*, pp. 294–301. Kingston, Canada, 1985.
- [34] R. R. Yager, A. Rybalov, "Uninorm aggregation operators," *Fuzzy Sets and Systems*, 80, 111–120, 1996.

# Caracterizaciones y equivalencias de algunas familias de funciones de implicación borrosas generadas a partir de cópulas

Sebastia Massanet\*<sup>†</sup>, Ana Pradera<sup>‡</sup>, Daniel Ruiz-Aguilera\*<sup>†</sup>, Joan Torrens\*<sup>†</sup>

\* Grupo de investigación en Soft Computing, Procesamiento de Imágenes y Agregación (SCOPIA)

Departamento de Ciencias Matemáticas e Informática

Universitat de les Illes Balears, 07122 Palma, España

<sup>†</sup>Instituto de Investigación Sanitaria de las Islas Baleares (IdISBa), 07010 Palma, España

<sup>‡</sup> Departamento de Ciencias de la Computación, Arquitectura de Computadores,

Lenguajes y Sistemas Informáticos y Estadística e Investigación Operativa

Universidad Rey Juan Carlos, 28933 Móstoles, Madrid, España

E-mails: s.massanet@uib.es, ana.pradera@urjc.es, daniel.ruiz@uib.es, jts224@uib.es

**Resumen**—Este trabajo es un resumen de los artículos [5] y [6] publicados en *Fuzzy Sets and Systems* para su presentación en la Multiconferencia CAEPIA'18 KeyWorks.

**Index Terms**—Función de implicación borrosa, cópula, implicación probabilística, implicación de supervivencia, implicación S-probabilística, implicación de S-supervivencia.

## I. RESUMEN

La caracterización y representación de los conectivos lógicos borrosos es una de las principales líneas de investigación en el campo teórico en lógica borrosa. Como consecuencia de este estudio, se ha conseguido caracterizar de forma axiomática un gran número de familias de conectivos lógicos borrosos. Por un lado, en el campo de las funciones de agregación, se han caracterizado varias familias de t-normas y t-conormas, cópulas y uninormas, entre otros operadores. Por otro lado, hay que destacar el esfuerzo de muchos investigadores en la caracterización de las familias de funciones de implicación borrosa. Así, se han caracterizado las  $(S, N)$ -implicaciones con  $N$  una negación borrosa continua, las  $R$ -implicaciones generadas a partir de t-normas continuas por la izquierda, sus respectivas generalizaciones derivadas de uninormas, las implicaciones  $f$  y  $g$ -generadas de Yager o las  $h$ -implicaciones, entre otras. La importancia de estos operadores radica en el gran número de aplicaciones que tienen en campos tan diversos como el razonamiento aproximado, el control borroso, el procesamiento de imágenes o la minería de datos. Se pueden consultar todas estas aplicaciones, en [1] y [2].

Una de las razones por las que las funciones de implicación borrosas son tan utilizadas es la flexibilidad existente en su definición:

*Definición 1:* Una operación binaria  $I : [0, 1]^2 \rightarrow [0, 1]$  se llama una *función de implicación borrosa* si satisface:

$$(I1) \quad I(x_1, y) \geq I(x_2, y) \quad \text{cuando} \quad x_1 \leq x_2, \text{ para todo } y \in [0, 1].$$

$$(I2) \quad I(x, y_1) \leq I(x, y_2) \quad \text{cuando} \quad y_1 \leq y_2, \text{ para todo } x \in [0, 1].$$

$$(I3) \quad I(0, 0) = I(1, 1) = 1 \quad \text{e} \quad I(1, 0) = 0.$$

Esta definición permite la existencia de una infinidad de familias de funciones de implicación borrosas. Cada una de estas familias satisface alguna propiedades adicionales que son útiles para algunas de las aplicaciones anteriormente mencionadas. De esta manera, dependiendo de la aplicación considerada, se puede escoger la función de implicación borrosa que satisface las propiedades adicionales deseables. Sin embargo, esta necesidad de disponer de un repertorio extenso de estos operadores ha tenido un efecto no deseado. En los últimos años, se han propuesto multitud de familias, algunas de una complejidad notable, cuya caracterización se desconoce. Esto ha provocado la aparición de familias, que aunque fueron presentadas como nuevas familias, después de estudiarlas en profundidad y obtener su caracterización, se demostró que tenían intersección o incluso que coincidían con familias ya conocidas. Por tanto, es de suma importancia caracterizar las familias de funciones de implicación borrosas introducidas hasta la fecha para conocer el comportamiento de cada familia y su relación con las demás.

Este ha sido el objetivo de los artículos [5] y [6]. En estos trabajos, se han caracterizado cuatro familias de funciones de implicación borrosas derivadas de cópulas y que fueron introducidas en [3] y [4] con la idea de combinar tanto la imprecisión modelada mediante los conceptos borrosos como la aleatoriedad proveniente de la teoría de probabilidades. Estas familias son las siguientes:

1) *Implicaciones probabilísticas:*

$$I_C(x, y) = \begin{cases} 1 & \text{si } x = 0, \\ \frac{C(x, y)}{x} & \text{si } x > 0, \end{cases}$$

donde  $C$  es una cópula que satisface  $C(x_1, y)x_2 \geq C(x_2, y)x_1$  para todo  $x_1 \leq x_2$  e  $y \in [0, 1]$ .

2) *Implicaciones de supervivencia:*

$$I_C^*(x, y) = \begin{cases} 1 & \text{si } x = 0, \\ \frac{x+y-1+C(1-x, 1-y)}{x} & \text{si } x > 0, \end{cases}$$



donde  $C$  es una cópula que satisface  $C(1-x_1, 1-y)x_2 - C(1-x_2, 1-y)x_1 \geq (1-y)(x_2-x_1)$  para todo  $x_1 \leq x_2$  e  $y \in [0, 1]$ .

- 3) *Implicaciones S-probabilísticas*:  $\tilde{I}_C(x, y) = C(x, y) - x + 1$  donde  $C$  es una cópula.
- 4) *Implicaciones de S-supervivencia*:  $\tilde{I}_C^*(x, y) = y + C(1-x, 1-y)$  donde  $C$  es una cópula.

Concretamente, en [5] se obtiene la caracterización de las implicaciones S-probabilísticas y de las implicaciones de S-supervivencia. En dicha caracterización, juegan un papel importante tanto el concepto de negación natural de una implicación dada por  $N_I(x) = I(x, 0)$ , como las propiedades adicionales siguientes:

- El principio de neutralidad por la izquierda,

$$I(1, y) = y, \quad y \in [0, 1]. \quad (\mathbf{NP})$$

- El 2-crecimiento,

$$I(x_2, y_1) + I(x_1, y_2) \leq I(x_1, y_1) + I(x_2, y_2), \quad (\mathbf{2-IC})$$

para todo  $x_1 \leq x_2$  e  $y_1 \leq y_2$ .

En este punto, la caracterización es la siguiente:

*Teorema 2:* Sea  $I : [0, 1]^2 \rightarrow [0, 1]$  una función binaria. Entonces las afirmaciones siguientes son equivalentes:

- i)  $I$  satisface **(NP)**, **(2-IC)**,  $N_I(x) = N_c(x) = 1 - x$  e  $I(0, y) = I(x, 1) = 1$  para todo  $x, y \in [0, 1]$ .
- ii)  $I$  es una implicación material generada por una co-cópula  $D$  y la negación borrosa  $N_c$ , i.e.,  $I(x, y) = D(1-x, y)$ .
- iii)  $I$  es una implicación S-probabilística generada por una cópula  $C$ .
- iv)  $I$  es una implicación de S-supervivencia generada por una cópula  $C'$ .

Además, las expresiones de  $D$ ,  $C$  y  $C'$  son únicas y vienen dadas por

$$\begin{aligned} D(x, y) &= I(1-x, y), \\ C(x, y) &= I(x, y) + x - 1, \\ C'(x, y) &= I(1-x, 1-y) + y - 1, \end{aligned}$$

para todo  $x, y \in [0, 1]$ .

La relevancia de este resultado radica en el hecho que se demuestra que las familias de implicaciones S-probabilísticas y de S-supervivencia son en realidad la misma y además, coinciden con las implicaciones materiales generadas por una co-cópula y  $N_c$ . Así, cualquier futuro estudio relativo a estas implicaciones puede centrarse en una sola de estas familias y los resultados pueden ser fácilmente reescritos en términos de las otras familias.

Un estudio similar se lleva a cabo en [6] para las familias de implicaciones probabilísticas e implicaciones de supervivencia. En dicho trabajo, se obtienen las caracterizaciones de estas familias demostrando de nuevo que ambas familias coinciden. El siguiente resultado aporta dicha caracterización.

*Teorema 3:* Sea  $I : [0, 1]^2 \rightarrow [0, 1]$  una función binaria. Entonces las afirmaciones siguientes son equivalentes:

- i)  $I$  es una implicación probabilística derivada de una cópula  $C$ .
- ii)  $I$  es una implicación de supervivencia derivada de una cópula  $C'$ .
- iii)  $I$  satisface **(I)**, **(NP)**,  $I(0, y) = 1$  para todo  $y \in [0, 1]$ , la propiedad

$$x_2 I(x_2, y_1) + x_1 I(x_1, y_2) \leq x_1 I(x_1, y_1) + x_2 I(x_2, y_2)$$

para todo  $x_1 \leq x_2$  e  $y_1 \leq y_2$  y

$$N_I(x) = N_{D_1}(x) = \begin{cases} 1 & \text{si } x = 0, \\ 0 & \text{en otro caso.} \end{cases}$$

Además, las expresiones de  $C$  y  $C'$  son únicas y vienen dadas por

$$\begin{aligned} C(x, y) &= xI(x, y), \\ C'(x, y) &= x + y - 1 + (1-x)I(1-x, 1-y), \end{aligned}$$

para todo  $x, y \in [0, 1]$ .

La coincidencia de estas dos familias puede demostrarse de forma alternativa usando el concepto de cópula de supervivencia  $C^*$  que a partir de una cópula  $C$ , se construye como  $C^*(x, y) = x + y - 1 + C(1-x, 1-y)$  para todo  $x, y \in [0, 1]$ .

*Teorema 4:* Sea  $C$  una cópula y sea  $I$  una función binaria. Entonces  $I$  es una implicación probabilística derivada de la cópula  $C$  si, y sólo si,  $I$  es una implicación de supervivencia derivada de la cópula  $C^*$ . Esto es,  $I_C = I_{C^*}$  o, equivalentemente,  $I_{C^*} = I_C$ .

En resumen, las caracterizaciones obtenidas en los artículos [5] y [6] han permitido, por una parte, reducir cinco familias de funciones de implicación borrosas a dos únicas familias y por otra parte, clarificar su estructura y propiedades adicionales. Esto permitirá simplificar el estudio de dichas familias y facilitar su aplicación en cualquier campo donde las funciones de implicación borrosa han demostrado su utilidad.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente subvencionado por los proyectos TIN2015-66471-P, TIN2016-75404-P AEI/FEDER, UE y TIN2016-81731-REDT.

#### REFERENCIAS

- [1] M. Baczyński and B. Jayaram. *Fuzzy Implications*, volume 231 of *Studies in Fuzziness and Soft Computing*. Springer, Berlin Heidelberg, 2008.
- [2] M. Baczyński, B. Jayaram, S. Massanet, and J. Torrens. Fuzzy implications: Past, present, and future. In J. Kacprzyk and W. Pedrycz, editors, *Springer Handbook of Computational Intelligence*, pages 183–202. Springer Berlin Heidelberg, 2015.
- [3] P. Grzegorzewski. Survival implications. In S. Greco et al., editor, *Advances on Computational Intelligence - 14th International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems, IPMU 2012. Proceedings, Part II*, volume 298 of *Communications in Computer and Information Science*, pages 335–344. Springer, 2012.
- [4] P. Grzegorzewski. Probabilistic implications. *Fuzzy Sets and Systems*, 226:53–66, 2013.
- [5] S. Massanet, A. Pradera, D. Ruiz-Aguilera, and J. Torrens. From three to one: Equivalence and characterization of material implications derived from co-copulas, probabilistic S-implications and survival S-implications. *Fuzzy Sets and Systems*, 323:103–116, 2017.
- [6] S. Massanet, A. Pradera, D. Ruiz-Aguilera, and J. Torrens. Equivalence and characterization of probabilistic and survival implications. *Fuzzy Sets and Systems*, 2018. Artículo en prensa. DOI=10.1016/j.fss.2018.06.014.



**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 2:  
APLICACIONES I







# Toma de decisiones a gran escala usando evaluación parcial de criterios. Caso aplicado a evaluación de conferencias

Jeronimo Duran, Rosana Montes y Francisco Herrera

Andalusian Research Institute on Data Science and Computational Intelligence, DaSCI

Universidad de Granada, Granada, España

Correos: jeronimoduran@correo.ugr.es, rosana@ugr.es, herrera@decsai.ugr.es

**Resumen**—Los eventos de divulgación son un medio de difusión muy importante para la comunidad científica, pues son esos espacios donde se dan a conocer los avances y las nuevas propuestas de investigación. El éxito de los medios de divulgación está directamente relacionado con la percepción que tienen los asistentes hacia dichos eventos. El poder evaluar estos eventos tomando en cuenta a los asistentes resulta interesante, por lo que se propone un modelo de evaluación que utiliza etiquetas lingüísticas, siendo este el recurso más adecuado para captar la opinión de los asistentes. Estos eventos, al ser masivos, se clasifica como un problema de toma de decisión a gran escala (LSGDM) que utilizan el modelo lingüístico de representación 2-tuplas para tener una toma de decisión en grupo con la mínima pérdida de información. La propuesta incluye una valoración parcial de criterios, es decir, el número de criterios a valorar puede variar durante el proceso de toma de decisión. MULTIMOORA permite generar un ranking de alternativas, y al realizar un análisis de los rankings obtenidos, podemos identificar cuales son los indicadores que se deben tomar en cuenta para que los eventos de divulgación tengan éxito, y se genere un plan de mejora continua de dichos eventos.

## I. INTRODUCCIÓN

La evaluación de eventos de divulgación científica ha sido abordada en la literatura especializada teniendo en cuenta indicadores que se obtienen a priori o a posteriori de dicho evento. Es habitual la clasificación de conferencias como CORE A, CORE B o CORE C, como el que otorga *The CORE Conference Ranking*<sup>1</sup>. Como propuesta para evaluar conferencias científicas de forma automática [1] [2], se puede tomar en cuenta el número de citas de los trabajos publicados en sus actas, el prestigio de la conferencia, el ratio de aceptación o la reputación de los miembros del comité del programa entre otros factores. Por otro lado, charlas, talleres y seminarios – que también son eventos divulgativos– no entran dentro del anterior esquema de evaluación basados en publicaciones de actas, pero cuentan con otros indicadores de evaluación como el número de asistentes, la reputación de los ponentes y la claridad de la charla entre otros. El conocer durante el transcurso del evento cuales son sus fortalezas y debilidades, genera información de gran valor para los organizadores y permitiría que las ediciones futuras sean de mejor calidad y aceptación.

<sup>1</sup><http://www.core.edu.au/conference-portal>

En la actualidad se está implementado una nueva tipología de proyectos científicos, en donde se hace partícipe a la ciudadanía, quienes aportan a las actividades de investigación científica esfuerzo intelectual, herramientas y recursos propios. El concepto que define lo anterior se conoce como Ciencia Ciudadana (CC)<sup>2</sup>. Este tipo de proyectos de investigación potencian la difusión de sus resultados y la participación a gran escala de la sociedad. Para la evaluación de eventos de divulgación científica en ciencia ciudadana se deben considerar otros factores (diferentes a los usados tradicionalmente), como por ejemplo aquellos criterios de calidad que resultan interesantes para los propios asistentes.

Frecuentemente las instituciones educativas realizan actividades de divulgación académica como conferencias y seminarios, cuya temática va acorde a las carreras que se ofertan en cada centro. Estos eventos no son evaluados en su mayoría, por lo que se desconoce el grado de aceptación por parte de la comunidad universitaria. Es importante el saber cuál es el grado de satisfacción que tiene la comunidad universitaria que asiste a este tipo de eventos, por lo que el contar con una herramienta que les permita recopilar la opinión de los asistentes es de gran importancia.

En todos los casos anteriores (conferencias, seminarios, eventos de ciencia ciudadana) se debe tomar en cuenta la opinión de los asistentes, pues son ellos quienes emiten su punto de vista sobre el evento y realizan la labor de publicitar dichos eventos dentro y fuera de las instituciones. Al emitir su valoración de una charla, están asignado valores a los indicadores definidos en un modelo de evaluación, siendo ésta un área de oportunidad para diseñar un modelo lingüístico de evaluación [3] que recoja esas valoraciones y permita emitir una valoración lingüística del éxito o fracaso del evento. Puesto que potencialmente se puede tener un número elevado de participantes, el modelo lingüístico se debe resolver como un Large Scale Group Decision Making (LSGDM).

El presente trabajo propone que en la evaluación de un evento los participantes determinen cuales son los criterios más importantes de acuerdo con su punto de vista así como la escala lingüística con la que desean evaluar dichos criterios.

<sup>2</sup><http://www.ibericivis.es/informe-del-observatorio-de-la-ciencia-ciudadana-2017/>

El uso de un enfoque lingüístico difuso facilita la expresión de una opinión pues permite utilizar lenguaje natural.

El documento se estructura de la siguiente forma. En la Sección II se describen de manera breve los modelos utilizados en el diseño de nuestra propuesta de evaluación parcial de criterios. La Sección III de forma descriptiva desarrolla el modelo propuesto y se ejemplifica con un caso de uso. Las conclusiones y trabajos futuros se exponen en Sección IV.

## II. PRELIMINARES

Se proporcionan las definiciones formales de los modelos representación de la información lingüística, representación lingüística de 2-tuplas y la técnica de resolución de toma de decisión MULTIMOORA.

### A. Toma de decisión dinámica a gran escala

El uso de modelos de toma de decisiones a gran escala (Large Scale Group Decision Making, LSGDM) [4] se ha enfocado como la simplificación de las opiniones de un gran grupo de expertos, tomados en muestras más pequeñas y tratando de conservar la heterogeneidad en sus opiniones. Tras realizar la agrupación o *clustering* [5], se les presenta el conjunto de alternativas que son evaluadas en este caso mediante relaciones de preferencia difusa. En la literatura se propone la elección dinámica de alternativas [6] [7], en donde se realiza un consenso entre expertos para determinar el o los criterios que serán añadidos o eliminados del sistema de evaluación o de toma de decisiones. Son propuestas interesantes que pueden ser incorporadas al modelo de evaluación de eventos propuesto, Al contar con un gran volumen de participantes en los eventos, se tiene un problema de toma de decisión a gran escala, en donde para poder determinar el grado de aceptación de los participantes se trabajará mediante *clusters* de preferencia.

### B. Representación de la información lingüística

Una jerarquía lingüística (Linguistic Hierarchies, LH [8] se define como la unión de un conjunto de términos lingüísticos equidistantes entre si, cuya granularidad de incertidumbre es impar; éstos se representan en niveles  $n(t)$ , donde  $t$  es un nivel válido de jerarquía.

$$LH = \cup_t S^{n(t)}(t), \quad t \in \{1, \dots, h\} \quad h = 3$$

$$S^{n(t)}(t) = \{s_0^{n(t)}, \dots, s_{\nu_t}^{n(t)}\} \quad \nu_t = n(t) - 1, \quad \nu_t \in \mathbb{N}.$$

Para realizar las transiciones entre cada uno de los niveles sucesivos, el término  $S^{n(t+1)}$  es definido por el punto medio de cada par de términos que pertenecen al nivel  $t$  anterior. los conjunto de etiquetas antiguo son utilizados como puntos de referencia. El conjunto conformado por los puntos de referencia  $t$  se define como:

$$FP_t = \{fp_t^0, \dots, fp_t^{2\nu_t}\}$$

Las reglas básicas de la jerarquías lingüísticas cuentan con limitantes, que no permiten trabajar bajo contextos que utilizan conjuntos de términos con 5, 7 y 9 etiquetas. Las

jerarquías lingüísticas extendidas (Extended Linguistic Hierarchies, ELH) [9] es un modelo que permite utilizar conjuntos de términos con  $\nu_1 = 5$ ,  $\nu_2 = 7$  y  $\nu_3 = 9$  valores y admite la representación lingüística 2-tuplas para evitar la pérdida de información. Es un modelo en donde se tiene un conjunto términos lingüísticos  $S^{n(t)}(t)$  ordenado según su granularidad  $n(t)$ . Cada conjunto corresponde a un nivel  $t$ , quien realizará una transición entre los niveles sucesivos.

En éste nuevo conjunto de términos lingüísticos con  $t^*$  (nivel donde van los cálculos) se mantienen los puntos de referencia definidos en LH.

$$n(t^*) = \left( \prod_{t=1}^h \nu_t \right) + 1 = \nu_{t^*} + 1$$

Es posible simplificar el término  $n(t^*)$ , calculando el mínimo común múltiplo (MCM) del valor de las granularidades del conjunto de términos en el ELH de la siguiente forma:

$$n(t^*) = LCM(\nu_1, \nu_2, \nu_3) + 1 = LCM(2, 4, 6) + 1 = 13$$

La expresión anterior nos muestra que los cálculos realizados pertenecen a  $S^{13}$ , que corresponde al MCM común entre los términos. En el EHL cada punto  $fp_{t^*}^i \in [0, 1]$  se localiza en:

$$j = \frac{i \cdot \nu_{t^*}}{\nu_t} \rightarrow FP_t \subset FP_{t^*} \quad \forall t = \{1, \dots, h\}$$

El uso de múltiples escalas lingüísticas no modifica el esquema de toma de decisión, solamente agrega un paso de *Unificación*. En el proceso de unificación, se traducen los datos lingüísticos de entrada mediante una función  $TF_{t^*}^t$  que transforma y convierte un término  $s_j \in S^{n(t)}$  en su equivalente  $s_k$  expresado en  $S^{n(t^*)}$  con  $t < t^*$ . De ésta forma se tiene la representación de cualquier valor del conjunto de términos lingüísticos. La función de transformación que se utiliza en la unificación esta dada por:

$$TF_{t^*}^t(s_j^{n(t)}, \alpha_j) = \Delta \left( \frac{\nu^{-1}(s_j^{n(t)}, \alpha_j) \cdot (n(t^*)-1)}{n(t)-1} \right) = (s_k^{n(t^*)}, \alpha_k) \quad (1)$$

Como ejemplo de unificación para datos procedentes de distintas escalas tenemos:

$$\begin{aligned} n(1) = 3; (s_1^3, 0) &\Rightarrow TF_{13}^3 = \Delta \left( \frac{1-12}{2} \right) = (s_6^{13}, 0) \\ n(2) = 5; (s_3^5, 0) &\Rightarrow TF_{13}^5 = \Delta \left( \frac{3-12}{4} \right) = (s_9^{13}, 0) \\ n(3) = 7; (s_4^7, 0) &\Rightarrow TF_{13}^7 = \Delta \left( \frac{4-12}{6} \right) = (s_8^{13}, 0) \end{aligned}$$

De ésta forma ya se puede trabajar con datos homogéneos, independientemente de que su representación original sea en una escala diferente.



### C. Representación lingüística de 2-tuplas

La 2-tuplas [10]  $(s_i, \alpha)$  es la representación de un término lingüístico  $s_i \in S = \{s_0, \dots, s_g\}$  válido para cálculos en procesos de computación.

- 1) Sea  $s_i \in S$  un término lingüístico cuya semántica es proporcionada por una función de membresía difusa.
- 2) Sea  $\alpha \in [-0.5, 0.5)$  el valor de *traducción simbólica* que indica la función de membresía difusa que representa el término mas cercano, cuando  $s_i \in S$  no coincide de forma exacta con la información lingüística calculada.
- 3) Los cálculos que se realizan de manera simbólica, operan con los índices de los términos lingüísticos y obtiene un valor  $\beta \in [0, g]$ .

La transformación de un termino lingüístico  $s_i \in S$  en un término lingüístico 2-tuplas, se realiza añadiendo a la traducción simbólica del término lingüístico un cero:

$$s_i \in S \longrightarrow (s_i, 0)$$

Sea  $(s_i, \alpha)$  un valor lingüístico 2-tuplas. Se tiene una función  $\Delta^{-1}$  que traduce un término 2-tuplas en un número  $\beta \in [0, g]$ :

$$\begin{aligned} \Delta^{-1} : S \times [-0.5, 0.5) &\rightarrow [0, g] \\ \Delta^{-1}(s_i, \alpha) &= i + \alpha = \beta \end{aligned} \quad (2)$$

Sea  $\beta \in [0, g]$  el resultado de un cálculo simbólico. El término equivalente 2-tuplas se obtiene mediante la función  $\Delta$  definida como:

$$\begin{aligned} \Delta : [0, g] &\rightarrow S \times [-0.5, 0.5) \\ \Delta(\beta) &= (s_i, \alpha), \text{ con } \begin{cases} s_i & i = \text{round}(\beta), \\ \alpha & \alpha = \beta - i \end{cases} \end{aligned} \quad (3)$$

Donde *round* es la función que asigna el entero más cercano  $i \in \{0, 1, \dots, g\}$  o puede ser utilizado como operador de redondeo,  $s_i$  denomina la etiqueta cuyo índice es el mas cercano al valor  $\beta$  y el valor de la traslación simbólica esta representada por  $\alpha$ .

Sea  $x = \{(s_1, \alpha_1), \dots, (s_n, \alpha_n)\}$  un conjunto de valores lingüísticos representados como 2-tuplas,  $W$  un vector de ponderación  $\{w_i | i = 1, \dots, n\}$ , y  $W'$  su versión normalizada como  $\sum_{i=1}^n w'_i = 1$ . Tenemos la media aritmética ponderada  $\bar{x}^e$  definida como:

$$\bar{x}^e(x) = \Delta \left( \frac{\sum_{i=1}^n \Delta^{-1}(s_i, \alpha_i) \cdot w_i}{\sum_{i=1}^n w_i} \right) = \Delta \left( \frac{1}{n} \sum_{i=1}^n \beta_i w'_i \right). \quad (4)$$

### D. MULTIMOORA 2-tuplas

El método ITL-MULTIMOORA [11] permite la solución de problemas de toma de decisión y ha sido aplicado con información lingüística 2-tuplas intervaluar, que permite representar datos complejos o incompletos. En nuestra propuesta lo hemos adaptamos para el uso 2-tuplas.

El método MULTIMOORA parte de valoraciones lingüísticas de expertos  $P_k$  ( $k = 1, 2, \dots, p$ ),  $A_i$

( $i = 1, 2, \dots, m$ ) alternativas y  $n$  criterios de evaluación  $C_j$  ( $j = 1, 2, \dots, n$ ).

Para desarrollar el MULTIMORA se parte de una de matriz de decisión como la siguiente:

$$X_k = \begin{bmatrix} x_{11}^k & x_{12}^k & \dots & x_{1n}^k \\ x_{21}^k & x_{22}^k & \dots & x_{2n}^k \\ \vdots & \vdots & \dots & \vdots \\ x_{m1}^k & x_{m2}^k & \dots & x_{mn}^k \end{bmatrix}$$

En  $x_{ij}^k \in S$ , donde  $S = \{s_i | i = 0, 1, 2, \dots, g\}$  representa la evaluación lingüística de  $A_i$  con respecto al criterio  $C_j$  dado por el experto  $P_k$ . Sea  $W_j$  los pesos proporcionados por cada uno de los expertos, donde  $w_j^k$  es un valor de peso asignada a  $C_j$  por  $P_k$ .

El modelo ITL-MULTIMOORA se desarrolla en los siguientes pasos:

**Paso 1** Se convierten la matrices de decisión  $X_k = (x_{ij}^k)_{m \times n}$  a matrices de decisión lingüística 2-tuplas:

$$\tilde{R}_k = (\tilde{r}_{ij}^k)_{m \times n} = ((x_{ij}^k, 0))_{m \times n} \text{ donde } x_{ij}^k \in S.$$

**Paso 2** Se calculan la normalización para las  $P$  matrices  $\tilde{R}'_k = (\tilde{r}'_{ij})_{m \times n}$ . Utilizando la siguiente expresión

$$\tilde{r}'_{ij} = \frac{w_j, (\Delta^{-1}(r_{ij}^k, 0))}{\sqrt{\sum_{i=1}^m (\Delta^{-1}(r_{ij}^k, 0))}} \quad (5)$$

**Paso 3** Para mejorar el proceso, se incorporan las evaluaciones de los expertos cuando es el caso de maximizar, y se sustraen cuando el caso es minimizar los criterios asociados a cada alternativa:

$$\tilde{y}_i = \sum_{j=1}^q \tilde{r}'_{ij} - \sum_{j=q+1}^n \tilde{r}'_{ij} \quad (6)$$

donde  $j = 1, 2, \dots, q$  son los criterios que serán maximizados,  $j = q + 1, q + 2, \dots, n$  son los valores que serán minimizados y  $\tilde{y}_i$  es la evaluación general de la alternativa  $A_i$  con respecto a todos los criterios evaluados.

**Paso 4** La utilidad global que tiene la  $i$ -ésima alternativa se puede expresar de la siguiente forma:

$$\tilde{u}_i = \tilde{a}_i / \tilde{b}_i \quad (7)$$

donde  $\tilde{a}_i = \prod_{j=1}^q \tilde{r}'_{ij}$  denota el producto del  $j$ -ésimo criterio que van a maximizarse, y  $\tilde{b}_i = \prod_{j=q+1}^n \tilde{r}'_{ij}$  que es el producto de criterios serán minimizados, siendo  $n - q$  el número de criterios que han de ser minimizados.

**Paso 5** El *ranking* de alternativas es dado por  $\tilde{y}_i$  y  $\tilde{u}_i$  para  $i = 1, 2, \dots, m$  en orden descendente.

### III. TOMA DE DECISIONES A GRAN ESCALA USANDO EVALUACIÓN PARCIAL DE LOS CRITERIOS

Se propone un modelo de evaluación de charlas partiendo del concepto de LSGDM en donde nuestros grupos de expertos serán los asistentes a las charlas impartidas. Se les dará a elegir de un conjunto de criterios y escalas de evaluación, que serán las escalas lingüísticas de nuestro problema de toma de decisiones multi-experto multi-criterio, para que después emitirán su valoración sobre la charla usando la escala y los criterios previamente seleccionados por ellos.

#### A. Metodología MULTIMOORA con evaluación parcial de criterios

Dentro del marco del Seminario Herramientas en Tecnologías Orientadas a la Educación, celebrado del 19 al 21 de junio de 2018 en donde participaron ponentes de la Universidad de Granada y la Universidad de Guadalajara, los cuales dieron una serie de charlas ( $a_1, a_2, a_3$ ) cuya finalidad era difundir información relevante en el ámbito educativo. Las charlas fueron dirigidas a la comunidad universitaria en general, teniendo como número máximo de asistentes 33; la concurrencia en cada una de las charlas fue variada, pero un gran número de los asistentes tuvieron una presencia constante. Al finalizar cada charla se les proporcionó un formulario en donde opinarían sobre tres aspectos del programa: ponente, contenidos y evento. Cada uno constaba de diferentes criterios los cuales serían elegidos por cada uno de los asistentes.

La finalidad de que los asistentes seleccionaran cuales eran los criterios más importantes de acuerdo con su juicio es identificar el peso que los asistentes les dan a cada criterio de forma individual. Dicha elección también nos proporciona información sobre que aspecto es el que más se valora. Además, se les proporcionó un espacio para que ellos pudieran agregar otros criterios diferentes a los proporcionadas en el formulario.

Durante el ejercicio se pudieron detectar nuevos criterios de evaluación que no se habían tomado en cuenta pero que si fueron considerados por la audiencia. Criterios como: Facilidad de palabra en el *cluster* de ponente, Exponer ideas, Aplicabilidad, Ejemplos prácticos y Tema en el *cluster* de contenidos, y Lugar/sala, y Ruido en el *cluster* de evento, los cuales se agregaron al esquema de evaluación final.

Finalmente los criterios de evaluación asignados a los *clusters* principales tomados para ésta propuesta fueron los siguientes:

- 1) Ponente: Vocalización ( $C_1$ ), Claridad de las expresiones ( $C_2$ ), Cercanía ( $C_3$ ), Dominio del tema ( $C_4$ ), Atención a la audiencia ( $C_5$ ) Facilidad de palabra ( $C_6$ ).
- 2) Contenidos: Calidad del contenido ( $C_7$ ), Claridad de las transparencias ( $C_8$ ), Adaptado al nivel ( $C_9$ ), Exponer ideas ( $C_{10}$ ), Aplicabilidad ( $C_{11}$ ), Ejemplos prácticos ( $C_{12}$ ), Tema ( $C_{13}$ ).
- 3) Evento: Duración ( $C_{14}$ ), Medios técnicos ( $C_{15}$ ), Iluminación ( $C_{16}$ ), Temperatura ( $C_{18}$ ), Lugar/sala ( $C_{17}$ ), Ruido ( $C_{19}$ )

Dentro del mismo formulario se les proporcionaban tres escalas de evaluación:  $S^3 = \{\text{poco, normal, mucho}\}$ ,  $S^5 = \{\text{poco, regular, normal, algo, mucho}\}$ ,  $S^7 = \{\text{nada, muy poco, regular, normal, algo, bastante, muchísimo}\}$ , y un espacio para que ellos pudieran proponer una escala diferente a las listadas. También se les proporciono la posibilidad de elegir la escala que ellos consideraran era la más adecuada para evaluar cada uno de los criterios. En su mayoría, los asistentes prefirieron utilizar la escala  $S^5$  para valorar los ítems de su preferencia siendo el 62% del total. Seguido de la escala  $S^7$  con el 25% y al final la escala  $S^3$  con el 13%.

Al final, y de forma individual, se evaluaron cada una de las charlas con los criterios y escalas elegidos. El modelo MULTIMOORA nos permite generar un ranking con los criterios elegidos por los asistentes, permitiendo que nos muestre cuales son aquellas charlas que tienen una mejor aceptación por parte de los asistentes. Éste ranking se obtiene por medio de índices de ordenación, los cuales se calculan conforme a los pasos descritos en la Sección II-D.

#### B. Valoraciones obtenidas

Una vez recopilada y concentrada toda la información obtenida de la evaluación de cada una de las charlas, se comenzó con el proceso descrito en la Sección II-D. Se unifican las escalas,  $s_k \in S^{13}$  utilizando Eq.(1), quedando simplificada de la siguiente forma:

$$TF_{t^*}^t(s_j^{n(t)}) = s_j^{n(t^*)} = s_k \quad (8)$$

En la Tabla IV se pueden observar todas las valoraciones obtenidas de las charlas proporcionadas por cada uno de los participantes. En ésta Tabla las valoraciones se encuentran unificados en la escala  $S^{13}$  tras la aplicación de Eq.(8).

Posteriormente los valores se transformaron en 2-tuplas y se realizó una agregación por experto usando peso uniforme. El resultado puede verse en la Tabla I.

Para el paso de normalización se requiere el cálculo previo de los pesos para los criterios como sigue:

$$w_j = \sum_i \delta(s_{ij}) \quad (9)$$
$$\text{con } \delta(s_{ij}) = \begin{cases} 1 & \text{si existe } s_{ij} \\ 0 & \text{si no existe } s_{ij} \end{cases}$$

La Tabla III muestras las valoraciones normalizadas que son expresadas sin dimensiones. La aplicación del método MULTIMOORA continua con la obtención de dos índices para cada una de las alternativas, índices que se utilizan para obtener un *ranking*. Los elementos mejor posicionados en el *ranking* están representados en la Tabla II. Para determinar las posiciones y mostrar la mejor opción se utilizó la teoría del dominio (*the theory of dominance* [12] en donde se comparan los ranking obtenidos (a, b, c). a;b;c, d-a-a es generalmente dominante que c-b-b, a-d-a es generalmente dominante que b-c-b, a-a-a es generalmente dominante que b-b-c.

El ranking que se obtuvo nos muestra que la alternativa  $a_1$  es la que tiene mejor posicionamiento tiene con respecto a



A	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	C <sub>6</sub>	C <sub>7</sub>	C <sub>8</sub>	C <sub>9</sub>	C <sub>10</sub>	C <sub>11</sub>	C <sub>12</sub>	C <sub>13</sub>	C <sub>14</sub>	C <sub>15</sub>	C <sub>16</sub>	C <sub>17</sub>	C <sub>18</sub>	C <sub>19</sub>
a <sub>1</sub>	(s <sub>12</sub> , 0)	(s <sub>9</sub> , -33)	(s <sub>12</sub> , 0)	(s <sub>11</sub> , 22)	(s <sub>11</sub> , 5)	(s <sub>0</sub> , 0)	(s <sub>11</sub> , 28)	(s <sub>12</sub> , 0)	(s <sub>10</sub> , 25)	-	-	-	(s <sub>12</sub> , 0)	(s <sub>9</sub> , 25)	(s <sub>10</sub> , 33)	-	-	-	-
a <sub>2</sub>	(s <sub>9</sub> , 43)	(s <sub>10</sub> , 46)	(s <sub>8</sub> , 0)	(s <sub>11</sub> , -37)	(s <sub>10</sub> , 5)	(s <sub>12</sub> , 0)	(s <sub>11</sub> , 47)	(s <sub>10</sub> , 0)	(s <sub>10</sub> , 19)	(s <sub>12</sub> , 0)	(s <sub>12</sub> , 0)	(s <sub>6</sub> , 0)	(s <sub>11</sub> , 5)	(s <sub>8</sub> , -4)	(s <sub>9</sub> , 22)	(s <sub>9</sub> , 0)	(s <sub>2</sub> , 0)	(s <sub>8</sub> , 0.12)	(s <sub>0</sub> , 0)
a <sub>3</sub>	(s <sub>10</sub> , -16)	(s <sub>9</sub> , -30)	(s <sub>9</sub> , -19)	(s <sub>11</sub> , -05)	(s <sub>10</sub> , -28)	-	(s <sub>10</sub> , -43)	(s <sub>7</sub> , 0)	(s <sub>10</sub> , -42)	-	-	-	-	(s <sub>7</sub> , 45)	(s <sub>10</sub> , 14)	-	-	(s <sub>6</sub> , 0)	-

TABLE I  
MATRIZ DE 2-TUPLAS CON LAS VALORACIONES POR ALTERNATIVA.

A	$\tilde{y}_i$	$\tilde{u}_i$	Valoración Media	Orden
a <sub>1</sub>	2.60	0	(s <sub>11</sub> , 0.318)	1
a <sub>2</sub>	2.46	0	(s <sub>9</sub> , 0.428)	3
a <sub>3</sub>	2.31	0	(s <sub>9</sub> , -0.116)	2

TABLE II  
RESULTADO DE LA UTILIDAD  $\tilde{y}_i$  Y EL DESEMPEÑO  $\tilde{u}_i$  DE CADA ALTERNATIVA, NECESARIOS PARA DETERMINAR EL RANKING.



Fig. 1. Distribución de preferencia sobre los criterios a evaluar

las otras dos opciones. En donde los criterios elegidos por los asistentes, pertenecientes a diferentes clusters, tuvieron valores altos en comparativa con las alternativas a<sub>2</sub> y a<sub>3</sub>. Para obtener información con la mínima pérdida, se utilizó el valor  $\alpha$  proporcionado por la representación lingüística 2-tuplas, el cual nos facilitó el posicionamiento en el ranking de aquellas opciones que se encontraban en la misma escala (s<sub>9</sub>), cómo fué el caso de las alternativas a<sub>2</sub> y a<sub>3</sub>, siendo la segunda mejor opción a<sub>3</sub> cuyo valoración es la mas cercana a la etiqueta del conjunto unificado.

Es importante resaltar que una mayor parte de los asistentes a las conferencias prefirieron seleccionar y evaluar criterios relacionados con los ponentes, los cual nos represento un 47.94% del total de las valoraciones obtenidas; en cuanto a los contenidos se obtuvo un 27.61% y para el evento 19.68% del total de las valoraciones. La Fig. 1 nos muestra en que proporción fueron elegidos cada uno de los criterios sin tomar en cuenta los clusters, siendo el criterio Dominio del tema (C<sub>4</sub>) el que fue elegido por un gran número de asistentes.

#### IV. CONCLUSIÓN

Los resultados que se obtuvieron al evaluar las charlas del seminario del caso de uso, nos mostraron que la evaluación de

una charla no siempre encaja en los métodos tradicionales. El diseñar un modelo en donde se utilicen etiquetas lingüísticas, para que los asistentes puedan expresar su incertidumbre con semántica difusa, puede ayudar a crear un plan de mejora continua de los eventos de divulgación. Tomando en cuenta el auge que está teniendo la CC, se debe considerar que las opiniones sobre las charlas saldrán de la ciudadanía, por tal motivo el instrumento de evaluación le debe permitir cierto grado de libertad para que el decida cuales son los criterios de mayor importancia al momento de expresar su valoración.

Para trabajo futuros, se buscará diseñar alguna aplicación móvil que recoja éstas valoraciones y puedan ser incorporadas a un modelo de evaluación de CC.

#### AGRADECIMIENTOS

Este trabajo fue parcialmente apoyado por el proyecto de investigación TIN2017-89517-P del Ministerio de Economía.

#### REFERENCIAS

- [1] W. Martins, M. Gonçalves, A. Laender, and G. Pappa, "Learning to assess the quality of scientific conferences: A case study in computer science," 2009, pp. 193–202.
- [2] O.-S. Loizides and P. Koutsakis, "On evaluating the quality of a computer science/computer engineering conference," *Journal of Informetrics*, vol. 11, no. 2, pp. 541–552, 2017.
- [3] C. Mi, X. Shan, Y. Qiang, Y. Stephanie, and Y. Chen, "A new method for evaluating tour online review based on grey 2-tuple linguistic," *Kybernetes*, vol. 43, no. 3, pp. 601–613, 2014.
- [4] S. Alonso, I. Pérez, F. Cabrerizo, and E. Herrera-Viedma, "A fuzzy group decision making model for large groups of individuals," 2009, pp. 643–648.
- [5] A. K. Jain, M. N. Murty, and P. J. Flynn, "Data clustering: A review," *ACM Comput. Surv.*, vol. 31, no. 3, pp. 264–323, 1999.
- [6] I. J. Perez, F. J. Cabrerizo, and E. Herrera-Viedma, "A mobile decision support system for dynamic group decision-making problems," *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 40, no. 6, pp. 1244–1256, 2010.
- [7] I. Pérez, F. Cabrerizo, and E. Herrera-Viedma, "Group decision making problems in a linguistic and dynamic context," *Expert Systems with Applications*, vol. 38, no. 3, pp. 1675–1688, 2011.
- [8] F. Herrera and L. Martínez, "A model based on linguistic 2-tuples for dealing with multigranular hierarchical linguistic contexts in multi-expert decision-making," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 31, no. 2, pp. 227–234, 2001.
- [9] E. Macarena, L. Jun, and M. Luis, "An extended hierarchical linguistic model for decision making problems," *Computational Intelligence*, vol. 27, no. 3, pp. 489–512, 2011.
- [10] F. Herrera and L. Martínez, "A 2-tuple fuzzy linguistic representation model for computing with words," *IEEE Transactions on fuzzy systems*, vol. 8, no. 6, pp. 746–752, 2000.
- [11] H.-C. Liu, J.-X. You, C. Lu, and M.-M. Shan, "Application of interval 2-tuple linguistic multimora method for health-care waste treatment technology evaluation and selection," *Waste Management*, vol. 34, no. 11, pp. 2355–2364, 2014.
- [12] W. Brauers and E. Zavadskas, "Robustness of multimora: A method for multi-objective optimization," *Informatica*, vol. 23, no. 1, pp. 1–25, 2012.



A	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	C <sub>6</sub>	C <sub>7</sub>	C <sub>8</sub>	C <sub>9</sub>	C <sub>10</sub>	C <sub>11</sub>	C <sub>12</sub>	C <sub>13</sub>	C <sub>14</sub>	C <sub>15</sub>	C <sub>16</sub>	C <sub>17</sub>	C <sub>18</sub>	C <sub>19</sub>
a <sub>1</sub>	0.22	0.28	0.15	0.54	0.21	0	0.43	0.10	0.18	-	-	-	0.07	0.23	0.14	-	-	-	-
a <sub>2</sub>	0.15	0.28	0.10	0.57	0.19	0.01	0.42	0.08	0.18	0.01	0.01	0.005	0.065	0.223	0.132	0.023	0.001	0.043	0
a <sub>3</sub>	0.189	0.280	0.122	0.558	0.209	-	0.425	0.062	0.194	-	-	-	-	0.174	0.148	-	-	0.053	-

TABLE III  
NORMALIZACIÓN DE LAS VALORACIONES.

A	P	LTS	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	C <sub>6</sub>	C <sub>7</sub>	C <sub>8</sub>	C <sub>9</sub>	C <sub>10</sub>	C <sub>11</sub>	C <sub>12</sub>	C <sub>13</sub>	C <sub>14</sub>	C <sub>15</sub>	C <sub>16</sub>	C <sub>17</sub>	C <sub>18</sub>	C <sub>19</sub>
a <sub>1</sub>	p <sub>1</sub>	S <sup>5</sup>	-	s <sub>9</sub>	-	s <sub>12</sub>	-	-	s <sub>12</sub>	-	s <sub>6</sub>	-	-	-	-	s <sub>12</sub>	-	-	-	-	-
a <sub>1</sub>	p <sub>2</sub>	S <sup>3</sup>	s <sub>12</sub>	-	-	s <sub>12</sub>	s <sub>6</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>6</sub>	-	-	-	-	-
a <sub>1</sub>	p <sub>3</sub>	S <sup>3</sup>	s <sub>12</sub>	-	-	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	s <sub>12</sub>	-	-	-	-
a <sub>1</sub>	p <sub>4</sub>	S <sup>5</sup>	-	s <sub>9</sub>	-	s <sub>9</sub>	-	-	s <sub>9</sub>	-	s <sub>9</sub>	-	-	-	-	-	s <sub>9</sub>	-	-	-	-
a <sub>1</sub>	p <sub>5</sub>	S <sup>5</sup>	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	s <sub>12</sub>	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>1</sub>	p <sub>6</sub>	S <sup>3</sup>	-	s <sub>12</sub>	-	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-
a <sub>1</sub>	p <sub>7</sub>	S <sup>7</sup>	-	s <sub>12</sub>	-	s <sub>10</sub>	s <sub>12</sub>	-	s <sub>10</sub>	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-	-
a <sub>1</sub>	p <sub>8</sub>	S <sup>7</sup>	-	s <sub>6</sub>	-	s <sub>8</sub>	-	-	s <sub>8</sub>	-	-	-	-	-	-	s <sub>8</sub>	s <sub>8</sub>	-	-	-	-
a <sub>1</sub>	p <sub>9</sub>	S <sup>7</sup>	-	s <sub>8</sub>	s <sub>12</sub>	s <sub>10</sub>	-	-	-	s <sub>12</sub>	-	-	-	-	s <sub>12</sub>	-	-	-	-	-	-
a <sub>2</sub>	p <sub>1</sub>	S <sup>5</sup>	s <sub>9</sub>	s <sub>6</sub>	-	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	-	s <sub>12</sub>	-	-	-	-
a <sub>2</sub>	p <sub>2</sub>	S <sup>3</sup>	s <sub>6</sub>	-	s <sub>0</sub>	-	-	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>6</sub>	-	s <sub>12</sub>	-	-	-
a <sub>2</sub>	p <sub>3</sub>	S <sup>5</sup>	-	s <sub>12</sub>	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>4</sub>	S <sup>7</sup>	-	s <sub>10</sub>	-	s <sub>12</sub>	s <sub>8</sub>	-	s <sub>8</sub>	-	-	-	-	-	-	-	s <sub>4</sub>	-	-	-	-
a <sub>2</sub>	p <sub>5</sub>	S <sup>5</sup>	-	-	s <sub>9</sub>	s <sub>12</sub>	-	-	-	-	s <sub>9</sub>	-	-	-	-	-	s <sub>3</sub>	s <sub>3</sub>	-	-	-
a <sub>2</sub>	p <sub>6</sub>	S <sup>5</sup>	-	s <sub>9</sub>	s <sub>6</sub>	s <sub>12</sub>	s <sub>6</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-	-	-
a <sub>2</sub>	p <sub>7</sub>	S <sup>7</sup>	-	s <sub>12</sub>	s <sub>12</sub>	-	-	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>10</sub>	-	-	-	s <sub>4</sub>	-
a <sub>2</sub>	p <sub>8</sub>	S <sup>7</sup>	s <sub>8</sub>	s <sub>10</sub>	-	s <sub>12</sub>	-	-	s <sub>8</sub>	-	-	-	-	-	-	s <sub>8</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>9</sub>	S <sup>5</sup>	s <sub>9</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	s <sub>9</sub>	s <sub>9</sub>	-	-	-	s <sub>9</sub>	-
a <sub>2</sub>	p <sub>10</sub>	S <sup>3</sup>	s <sub>12</sub>	-	s <sub>6</sub>	s <sub>6</sub>	-	-	s <sub>6</sub>	-	-	-	-	-	-	s <sub>6</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>11</sub>	S <sup>5</sup>	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>9</sub>	-	-	s <sub>12</sub>	-	s <sub>9</sub>	-	-	-	-	-	-	-	-	-	-
a <sub>2</sub>	p <sub>12</sub>	S <sup>7</sup>	-	-	-	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>10</sub>	-	-	-	s <sub>2</sub>	-
a <sub>2</sub>	p <sub>13</sub>	S <sup>5</sup>	-	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	s <sub>9</sub>	s <sub>9</sub>	-	-	s <sub>3</sub>	-
a <sub>2</sub>	p <sub>14</sub>	S <sup>7</sup>	s <sub>8</sub>	-	-	s <sub>10</sub>	-	-	-	-	s <sub>8</sub>	-	-	-	-	s <sub>8</sub>	-	s <sub>12</sub>	-	-	-
a <sub>2</sub>	p <sub>15</sub>	S <sup>5</sup>	-	s <sub>12</sub>	-	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-
a <sub>2</sub>	p <sub>16</sub>	S <sup>5</sup>	s <sub>9</sub>	-	s <sub>6</sub>	s <sub>12</sub>	-	-	s <sub>9</sub>	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>17</sub>	S <sup>5</sup>	s <sub>6</sub>	-	-	s <sub>12</sub>	-	-	s <sub>9</sub>	-	-	-	-	-	-	s <sub>6</sub>	-	-	-	s <sub>3</sub>	-
a <sub>2</sub>	p <sub>18</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	-	-	s <sub>9</sub>	s <sub>12</sub>	-	-	-	-	-	-	s <sub>9</sub>	-	-	s <sub>6</sub>	-
a <sub>2</sub>	p <sub>19</sub>	S <sup>3</sup>	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	s <sub>12</sub>	-	-	-	-
a <sub>2</sub>	p <sub>20</sub>	S <sup>5</sup>	-	s <sub>12</sub>	s <sub>9</sub>	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>21</sub>	S <sup>5</sup>	s <sub>9</sub>	-	-	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>9</sub>	-	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-
a <sub>2</sub>	p <sub>22</sub>	S <sup>5</sup>	s <sub>3</sub>	-	-	s <sub>9</sub>	-	-	-	s <sub>6</sub>	s <sub>3</sub>	-	-	-	-	-	-	-	-	s <sub>12</sub>	-
a <sub>2</sub>	p <sub>23</sub>	S <sup>5</sup>	s <sub>9</sub>	-	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	s <sub>1</sub>	-
a <sub>2</sub>	p <sub>24</sub>	S <sup>3</sup>	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>6</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>25</sub>	S <sup>5</sup>	-	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	s <sub>12</sub>	-	-	-	-	s <sub>12</sub>	s <sub>9</sub>	-	-	-	-	-
a <sub>2</sub>	p <sub>26</sub>	S <sup>5</sup>	s <sub>3</sub>	s <sub>3</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	-
a <sub>2</sub>	p <sub>27</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	s <sub>9</sub>	-	-	-	-	-	-	-	s <sub>9</sub>	s <sub>12</sub>	-	-	-	s <sub>0</sub>	-
a <sub>2</sub>	p <sub>28</sub>	S <sup>7</sup>	-	-	s <sub>12</sub>	-	s <sub>12</sub>	-	s <sub>10</sub>	s <sub>10</sub>	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-
a <sub>2</sub>	p <sub>29</sub>	S <sup>5</sup>	-	s <sub>6</sub>	-	s <sub>12</sub>	-	-	s <sub>9</sub>	-	s <sub>9</sub>	-	-	-	-	-	s <sub>9</sub>	-	-	-	-
a <sub>2</sub>	p <sub>30</sub>	S <sup>7</sup>	s <sub>10</sub>	s <sub>12</sub>	s <sub>12</sub>	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-	-	-
a <sub>2</sub>	p <sub>31</sub>	S <sup>7</sup>	-	-	-	s <sub>8</sub>	-	-	-	-	-	-	s <sub>12</sub>	s <sub>6</sub>	s <sub>12</sub>	-	-	-	s <sub>2</sub>	-	-
a <sub>2</sub>	p <sub>32</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	s <sub>6</sub>	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	s <sub>0</sub>
a <sub>2</sub>	p <sub>33</sub>	S <sup>3</sup>	-	-	-	-	-	s <sub>12</sub>	-	-	-	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-
a <sub>3</sub>	p <sub>1</sub>	S <sup>5</sup>	-	s <sub>12</sub>	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>9</sub>	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>2</sub>	S <sup>5</sup>	-	s <sub>3</sub>	-	-	s <sub>6</sub>	-	s <sub>9</sub>	-	-	-	-	-	-	s <sub>9</sub>	s <sub>12</sub>	-	-	-	-
a <sub>3</sub>	p <sub>3</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>9</sub>	-	s <sub>9</sub>	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>4</sub>	S <sup>7</sup>	-	s <sub>10</sub>	-	s <sub>10</sub>	s <sub>12</sub>	-	s <sub>10</sub>	-	s <sub>10</sub>	-	-	-	-	-	-	-	-	-	-
a <sub>3</sub>	p <sub>5</sub>	S <sup>5</sup>	-	s <sub>12</sub>	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>6</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	s <sub>12</sub>	-	-	-	-
a <sub>3</sub>	p <sub>7</sub>	S <sup>5</sup>	s <sub>12</sub>	s <sub>12</sub>	s <sub>12</sub>	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-	-	-
a <sub>3</sub>	p <sub>8</sub>	S <sup>5</sup>	-	-	-	s <sub>9</sub>	s <sub>9</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>0</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>9</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	s <sub>12</sub>	-	-	-
a <sub>3</sub>	p <sub>10</sub>	S <sup>5</sup>	-	s <sub>6</sub>	-	s <sub>9</sub>	-	-	s <sub>6</sub>	-	s <sub>9</sub>	-	-	-	-	-	s <sub>9</sub>	-	-	-	-
a <sub>3</sub>	p <sub>11</sub>	S <sup>7</sup>	s <sub>6</sub>	s <sub>10</sub>	-	s <sub>10</sub>	-	-	s <sub>6</sub>	-	-	-	-	-	-	s <sub>6</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>12</sub>	S <sup>5</sup>	-	-	-	s <sub>12</sub>	s <sub>9</sub>	-	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	s <sub>9</sub>	-	-	-	-
a <sub>3</sub>	p <sub>13</sub>	S <sup>5</sup>	-	s <sub>9</sub>	s <sub>12</sub>	s <sub>12</sub>	-	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-	s <sub>9</sub>	-
a <sub>3</sub>	p <sub>14</sub>	S <sup>5</sup>	-	-	-	s <sub>9</sub>	-	-	-	s <sub>6</sub>	-	-	-	-	-	s <sub>0</sub>	s <sub>3</sub>	-	-	s <sub>3</sub>	-
a <sub>3</sub>	p <sub>15</sub>	S <sup>5</sup>	s <sub>9</sub>	s <sub>6</sub>	-	s <sub>12</sub>	s <sub>12</sub>	-	-	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>16</sub>	S <sup>5</sup>	-	s <sub>9</sub>	s <sub>6</sub>	s <sub>9</sub>	s <sub>12</sub>	-	-	-	-	-	-	-	-	s <sub>9</sub>	-	-	-	-	-
a <sub>3</sub>	p <sub>17</sub>	S <sup>7</sup>	-	s <sub>12</sub>	s <sub>10</sub>	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	-	-	-	-	-	-	-	-	-
a <sub>3</sub>	p <sub>18</sub>	S <sup>7</sup>	s <sub>10</sub>	-	s <sub>6</sub>	s <sub>12</sub>	-	-	-	s <sub>6</sub>	-	-	-	-	-	-	s <sub>12</sub>	-	-	-	-
a <sub>3</sub>	p <sub>19</sub>	S <sup>5</sup>	s <sub>12</sub>	-	-	-	s <sub>12</sub>	-	s <sub>12</sub>	s <sub>12</sub>	-	-	-	-	-	s <sub>9</sub>	s <sub>12</sub>	-	-	-	-
a <sub>3</sub>	p <sub>20</sub>	S <sup>7</sup>	-	s <sub>8</sub>	-	s <sub>10</sub>	s <sub>12</sub>	-	s <sub>10</sub>	s <sub>4</sub>	-	-	-	-	-	-	-	-	-	-	-
a <sub>3</sub>	p <sub>21</sub>	S <sup>5</sup>	s <sub>12</sub>	s <sub>12</sub>	-	s <sub>12</sub>	-	-	-	s <sub>9</sub>	-	-	-	-	-	s <sub>3</sub>	-	-	-	-	-
	W		33%	54%	24%	90%	37%	2%	73%	16%	33%	2%	2%	2%	11%	48%	27%	5%	2%	16%	2%

TABLE IV

VALORACIONES RECIBIDAS EN LAS CHARLAS TRAS LA UNIFICACIÓN A LA ESCALA S<sup>13</sup>. LOS PESOS CALCULADOS HACEN REFERENCIA AL NÚMERO DE VECES QUE SE USÓ UN CRITERIO.



# Escalas cualitativas: Aplicación de un nuevo enfoque basado en proximidades

Raquel González del Pozo  
*PRESAD, IMUVA*  
*Dep. de Economía Aplicada*  
*Universidad de Valladolid*  
 Valladolid  
 raquel.gonzalez.pozo@uva.es

José Luis García Lapresta  
*PRESAD, BORDA, IMUVA*  
*Dep. de Economía Aplicada*  
*Universidad de Valladolid*  
 Valladolid  
 lapresta@eco.uva.es

**Resumen**—La asignación de números a los términos lingüísticos de las escalas cualitativas es muy habitual en el ámbito de las Ciencias Sociales. Sin embargo, esta asignación carece de sentido cuando las escalas son no uniformes, es decir, cuando los individuos aprecian proximidades distintas entre los términos consecutivos de las mismas.

En este trabajo se propone un procedimiento ordinal para ordenar un conjunto de alternativas a partir de las valoraciones mostradas por los individuos mediante una escala cualitativa no necesariamente uniforme. Dicho procedimiento evita el uso de números en las valoraciones cualitativas y se basa en las proximidades ordinales entre los términos lingüísticos de las escalas. El procedimiento propuesto se ilustra con un ejemplo tomado de los Barómetros del Centro de Investigaciones Sociológicas.

**Palabras clave**—escalas cualitativas, encuestas, CIS

## I. INTRODUCCIÓN

El creciente interés por conocer las preferencias, opiniones y necesidades de la población ante determinadas políticas económicas y sociales hace que se utilicen cada vez más escalas cualitativas formadas por términos lingüísticos en los cuestionarios y encuestas.

El uso de escalas cualitativas formadas por palabras permite a los seres humanos expresarse de una forma sencilla ante situaciones de vaguedad e imprecisión. Autores como Zimmer [10] señalan que la mayoría de las personas prefiere comunicar sus opiniones inciertas a través de las palabras que con valores numéricos, ya que las expresiones verbales se ajustan mejor a sus pensamientos que los números.

No obstante, y a pesar de la preferencia de los seres humanos por las palabras, la gran mayoría de encuestas y cuestionarios miden las actitudes y el grado de acuerdo de los encuestados ante determinadas cuestiones mediante escalas tipo Likert [8], a cuyos términos lingüísticos se les asignan valores numéricos.

Estas asignaciones de valores numéricos (habitualmente equidistantes) carecen de sentido en el contexto de las escalas cualitativas no uniformes, es decir, cuando los individuos aprecian proximidades distintas entre los términos consecutivos de la escala, pudiendo generar diferentes resultados en función de cómo se codifique numéricamente la escala (véanse Roberts [9] y Franceschini et al. [4] entre otros).

Por otra parte, el Centro de Investigaciones Sociológicas (CIS) y otros organismos nacionales e internacionales presentan los resultados de sus investigaciones agrupando determinados términos lingüísticos. En la metodología de los anuarios del CIS [3] puede comprobarse que términos como “Mucho” y “Bastante”, utilizados en algunas preguntas de batería para conocer el grado de acuerdo de los encuestados ante determinadas cuestiones, han sido agrupados, descartándose el resto de términos lingüísticos de la escala (“Poco” y “Nada”). Este tratamiento supone una pérdida importante de la información cualitativa de las escalas, además de no considerar la no uniformidad de las mismas.

En este trabajo se plantea cómo ordenar un conjunto de alternativas valoradas cualitativamente a través del procedimiento puramente ordinal propuesto recientemente por García-Lapresta y Pérez-Román [7]. Este procedimiento evita el uso de números en las valoraciones cualitativas y considera únicamente las proximidades entre los términos de las escalas, por lo que puede ser aplicado en el contexto de escalas cualitativas no uniformes. En el presente trabajo también se incluye una comparación entre el procedimiento puramente ordinal antes mencionado y la metodología correspondiente a la agrupación de varios términos lingüísticos utilizando datos del Barómetro del CIS de mayo de 2011.

## II. PROCEDIMIENTO

Se considerará un conjunto de agentes  $A = \{1, \dots, m\}$ , con  $m \geq 2$ , que evalúan un conjunto de alternativas  $X = \{x_1, \dots, x_n\}$ , con  $n \geq 2$ , a través una escala cualitativa ordenada  $\mathcal{L} = \{l_1, \dots, l_g\}$ , con  $g \geq 3$  y  $l_1 < l_2 < \dots < l_g$ .

Con objeto de evitar la asignación de números a los términos lingüísticos de escalas cualitativas no uniformes y manejar su información de una forma puramente ordinal, en este trabajo utilizamos la noción de medida de proximidad ordinal introducida por García-Lapresta y Pérez-Román [6].

Una medida de proximidad ordinal es una función que asigna un grado de proximidad a cada par de términos lingüísticos de una escala cualitativa ordenada  $\mathcal{L}$ . Estos grados de proximidad pertenecen a un orden lineal  $\Delta = \{\delta_1, \dots, \delta_h\}$ , con  $\delta_1 \succ \dots \succ \delta_h$ , denotando  $\delta_1$  y  $\delta_h$  la máxima y la mínima proximidad, respectivamente. Es importante destacar que los

elementos de  $\Delta$  no son números, son solo objetos abstractos, que representan diferentes grados de proximidad.

**Definición 1:** [6] Una *medida de proximidad ordinal* sobre  $\mathcal{L}$  con valores en  $\Delta$  es una función  $\pi : \mathcal{L}^2 \rightarrow \Delta$ , donde  $\pi(l_r, l_s) = \pi_{rs}$  denota el grado de proximidad entre  $l_r$  y  $l_s$ , que satisface las condiciones siguientes:

- 1) *Exhaustividad:* Para cada  $\delta \in \Delta$ , existen  $l_r, l_s \in \mathcal{L}$  tales que  $\delta = \pi_{rs}$ .
- 2) *Simetría:*  $\pi_{sr} = \pi_{rs}$ , para cualesquiera  $r, s \in \{1, \dots, g\}$ .
- 3) *Máxima proximidad:*  $\pi_{rs} = \delta_1 \Leftrightarrow r = s$ , para cualesquiera  $r, s \in \{1, \dots, g\}$ .
- 4) *Monotonía:*  $\pi_{rs} \succ \pi_{rt}$  y  $\pi_{st} \succ \pi_{rt}$ , para cualesquiera  $r, s, t \in \{1, \dots, g\}$  tales que  $r < s < t$ .

Toda medida de proximidad ordinal puede representarse mediante la *matriz de proximidades*

$$\begin{pmatrix} \pi_{11} & \cdots & \pi_{1s} & \cdots & \pi_{1g} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \pi_{r1} & \cdots & \pi_{rs} & \cdots & \pi_{rg} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \pi_{g1} & \cdots & \pi_{gs} & \cdots & \pi_{gg} \end{pmatrix},$$

que es simétrica y de dimensión  $g \times g$ , con coeficientes en  $\Delta$ , y cuyos elementos de la diagonal principal son  $\pi_{rr} = \delta_1$ ,  $r = 1, \dots, g$ , y  $\pi_{1g} = \delta_h$  (véase García-Lapresta y Pérez-Román [6, Prop. 2]).

Las valoraciones dadas por los agentes a cada una de las alternativas son recogidas en un *perfil*

$$V = \begin{pmatrix} v_1^1 & \cdots & v_i^1 & \cdots & v_n^1 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ v_1^a & \cdots & v_i^a & \cdots & v_n^a \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ v_1^m & \cdots & v_i^m & \cdots & v_n^m \end{pmatrix},$$

donde el elemento  $v_i^a \in \mathcal{L}$  es la valoración lingüística otorgada por el agente  $a \in A$  a la alternativa  $x_i \in X$ .

Una vez fijada la medida de proximidad ordinal y conocidas las valoraciones lingüísticas dadas por los agentes a cada una de las alternativas, puede aplicarse el procedimiento introducido por García-Lapresta y Pérez-Román [7] para ordenar las alternativas.

El procedimiento está dividido en los siguientes pasos.

- 1) Para cada alternativa  $x_i \in X$  se seleccionan las valoraciones de  $x_i$  otorgadas por todos los agentes:  $v_i^1, \dots, v_i^m \in \mathcal{L}$  (columna  $i$  de  $V$ ).
- 2) Para cada alternativa  $x_i \in X$  se calculan los grados de proximidad entre las valoraciones dadas por los agentes y la máxima valoración posible de la escala,  $l_g$ :

$$\pi(v_i^1, l_g), \dots, \pi(v_i^m, l_g) \in \Delta.$$

- 3) Para cada alternativa  $x_i \in X$  se ordenan de forma decreciente los grados de proximidad obtenidos. Una vez ordenados, con objeto de evitar la pérdida de información, se selecciona el par de medianas de grados de proximidad,  $M_i$ , de la siguiente forma:

- a) Si el número de valoraciones es par, entonces se tienen en cuenta las dos medianas  $M_i = (\delta_r, \delta_s)$ , con  $r, s \in \{1, \dots, h\}$  tales que  $r \leq s$ .
- b) Si el número de valoraciones es impar, se duplica la mediana. Por tanto,  $M_i = (\delta_r, \delta_r)$  para algún  $r \in \{1, \dots, h\}$ .

Por consiguiente,  $M_i \in \Delta_2$ , donde  $\Delta_2$  es el *conjunto de medianas factibles*:

$$\Delta_2 = \{(\delta_r, \delta_s) \in \Delta^2 \mid r \leq s\}.$$

- 4) Se ordenan los pares de medianas de grados de proximidad obtenidos previamente para cada una de las alternativas, considerando el orden lineal  $\succeq$  sobre  $\Delta_2$  definido como

$$\begin{aligned} (\delta_r, \delta_s) \succeq (\delta_t, \delta_u) &\Leftrightarrow \\ \begin{cases} r + s < t + u \\ \text{o} \\ r + s = t + u \text{ y } s - r \leq u - t, \end{cases} & \quad (1) \end{aligned}$$

para cualesquiera  $(\delta_r, \delta_s), (\delta_t, \delta_u) \in \Delta_2$ .

- 5) Se ordenan las alternativas a través del orden débil  $\succcurlyeq$  sobre  $X$  definido como  $x_i \succcurlyeq x_j \Leftrightarrow M_i \succeq M_j$ , donde  $\succeq$  es el orden lineal definido en (1).

Al ordenar las alternativas es posible que algunas de ellas estén empatadas por tener el mismo par de medianas. En estos casos puede utilizarse un proceso secuencial de desempate basado en Balinski y Laraki [1]. Este procedimiento consiste en eliminar las dos medianas de las alternativas que están empatadas, seleccionar el nuevo par de medianas de entre los grados de proximidad restantes y aplicar el procedimiento del paso 4 hasta romper los empates y ordenar todas las alternativas.

### III. APLICACIÓN A LAS ESCALAS CUALITATIVAS DEL CENTRO DE INVESTIGACIONES SOCIOLÓGICAS

En esta sección se presenta una comparación entre la metodología de agrupación de varios términos lingüísticos y el procedimiento puramente ordinal de la sección II.

Para ello se han tomado los datos de la pregunta 20 del Barómetro del CIS de mayo de 2011 [2], en la cual se pide a los individuos que manifiesten, a través de la escala cualitativa de la Tabla I, hasta qué punto confiarían en la ayuda que les puedan proporcionar las nueve alternativas contenidas en la Tabla II ante una situación de catástrofe o desastre.

La muestra utilizada asciende a 2.219 individuos, de los cuales 1.114 son hombres y 1.105 son mujeres.

Para la aplicación del procedimiento ordinal introducido en la sección II es necesario utilizar una medida de proximidad



ordinal adecuada. Con objeto de establecer esta medida, se realizó una encuesta acerca de las proximidades entre los términos de la escala de la Tabla I dirigida a estudiantes de cuarto curso del grado en Economía de la Universidad de Valladolid. Una vez conocidas sus respuestas, se obtuvieron las medidas de proximidad ordinal para cada uno de los estudiantes y se aplicó el procedimiento de agregación introducido por García-Lapresta et al. [5] para determinar la medida de proximidad ordinal que mejor representaba las opiniones de los encuestados.

La medida de proximidad ordinal resultante es la asociada a la matriz

$$A_{232} = \begin{pmatrix} \delta_1 & \delta_2 & \delta_4 & \delta_5 \\ & \delta_1 & \delta_3 & \delta_4 \\ & & \delta_1 & \delta_2 \\ & & & \delta_1 \end{pmatrix}$$

representada en la Fig. 1.



Fig. 1. Medida de proximidad ordinal asociada a la matriz  $A_{232}$ .

Una vez determinada la medida de proximidad ordinal, se ordenan las nueve alternativas de la Tabla II mediante aplicación del procedimiento ordinal de la sección II.

Para ello, se calculan los grados de proximidad ordinal entre las valoraciones dadas por los agentes y la máxima valoración posible de la escala ( $l_4$ ). Seguidamente, estos grados de proximidad se ordenan de mayor a menor proximidad y se selecciona de cada alternativa su par de medianas.

Los pares de medianas obtenidos “considerando la población total” son los siguientes:  $M_1 = M_2 = M_3 = M_4 = M_5 = M_6 = M_8 = M_9 = (\delta_2, \delta_2)$  y  $M_7 = (\delta_1, \delta_1)$ .

Aplicando (1) se obtiene  $M_7 \succ M_1 = M_2 = M_3 = M_4 = M_5 = M_6 = M_8 = M_9$ , luego la alternativa  $x_7$  (Familiares) ocupa la primera posición del orden.

A continuación, con objeto de ordenar el resto de alternativas, se aplica el procedimiento de desempate descrito en la sección II, obteniéndose las siguientes medianas:  $M_1^{(1)} = M_2^{(1)} = M_4^{(1)} = M_5^{(1)} = M_6^{(1)} = M_8^{(1)} = M_9^{(1)} = (\delta_2, \delta_2)$  y  $M_3^{(1)} = (\delta_1, \delta_2)$ .

Entonces por (1)  $M_3^{(1)} \succ M_1^{(1)} = M_2^{(1)} = M_4^{(1)} = M_5^{(1)} = M_6^{(1)} = M_8^{(1)} = M_9^{(1)}$ , luego la alternativa  $x_3$  (Bomberos) ocupa la segunda posición del orden.

El procedimiento de desempate se aplica las veces que sean necesarias hasta ordenar las nueve alternativas.

Finalmente, los resultados obtenidos después de la aplicación del procedimiento ordinal aparecen recogidos en la Tabla III. En dicha tabla también se muestran los órdenes obtenidos al agrupar los términos “Mucho” y “Bastante”.

Observando los resultados de la Tabla III cabe señalar, en primer lugar, que no existen diferencias en las posiciones ocupadas por las alternativas vecinos y ONGs, las cuales ocupan

Tabla I  
TÉRMINOS LINGÜÍSTICOS

$l_1$	Nada
$l_2$	Poco
$l_3$	Bastante
$l_4$	Mucho

Tabla II  
ALTERNATIVAS

$x_1$	Guardia Civil
$x_2$	ONGs
$x_3$	Bomberos
$x_4$	Protección Civil
$x_5$	Policía
$x_6$	Ejército
$x_7$	Familiares
$x_8$	Vecinos
$x_9$	Amigos

en todos los órdenes de la tabla la séptima y octava posición, respectivamente. En cambio, sí que existen diferencias en la forma de ordenar el resto de alternativas.

Si no se hace distinciones entre género, las diferencias entre los órdenes obtenidos mediante la agrupación de los términos lingüísticos y la aplicación del procedimiento ordinal se encuentran en las alternativas Protección Civil, Ejército, Policía y Guardia Civil. Como puede observarse, Protección Civil y el Ejército, que ocupan la cuarta y la quinta posición, respectivamente, en el orden resultante de agrupar de “Mucho” y “Bastante”, invierten sus posiciones en el caso del orden obtenido tras aplicar el procedimiento ordinal, sucediendo lo mismo en el caso de la Policía y la Guardia Civil.

En cuanto a los hombres, existen diferencias significativas en las primeras posiciones de los órdenes. Los bomberos y los familiares ocupan la primera y la segunda posición, respectivamente, en el orden obtenido tras la agrupación de los términos “Mucho” y “Bastante”. Sin embargo, si se considera el procedimiento ordinal, los familiares se sitúan en la primera posición seguidos por los bomberos. Protección Civil y Ejército también sufren modificaciones, invirtiéndose las posiciones que ocupan en los órdenes resultantes.

En el caso de las mujeres, las diferencias entre los dos órdenes son poco relevantes, variando únicamente las posiciones de la Policía y la Guardia Civil.

#### IV. CONCLUSIONES

La representación de las escalas cualitativas a través de valores numéricos exactos es muy común en el ámbito de las Ciencias Sociales debido a las facilidades que proporciona la Estadística a la hora de manejar datos numéricos. Sin embargo, este enfoque cuantitativo de la información cualitativa carece de sentido en el contexto de las escalas cualitativas no uniformes, ya que contradice algunos principios de la teoría de la medición (véase Roberts [9]).

Por otra parte, la práctica utilizada por el CIS y otros organismos consistente en presentar los resultados de sus

Tabla III  
 ÓRDENES OBTENIDOS TRAS LA AGRUPACIÓN DE “MUCHO” Y  
 “BASTANTE” Y LA APLICACIÓN DEL PROCEDIMIENTO ORDINAL

[10] Zimmer, A.C.: Verbal vs. numerical processing of subjective probabilities. *Decision Making Under Uncertainty* 16, pp. 159-182, 1983.

Agrupación “Mucho” y “Bastante”

Total		Hombres		Mujeres	
1	Familiares	1	Bomberos	1	Familiares
2	Bomberos	2	Familiares	2	Bomberos
3	Amigos	3	Amigos	3	Amigos
4	Protección Civil	4	Protección Civil	4	Protección Civil
5	Ejército	5	Ejército	5	Ejército
6	Policía	6	Guardia Civil	6	Policía
7	Guardia Civil	7	Policía	7	Guardia Civil
8	Vecinos	8	Vecinos	8	Vecinos
9	ONGs	9	ONGs	9	ONGs

Procedimiento ordinal

Total		Hombres		Mujeres	
1	Familiares	1	Familiares	1	Familiares
2	Bomberos	2	Bomberos	2	Bomberos
3	Amigos	3	Amigos	3	Amigos
4	Ejército	4	Ejército	4	Protección Civil
5	Protección Civil	5	Protección Civil	5	Ejército
6	Guardia Civil	6	Guardia Civil	6	Guardia Civil
7	Policía	7	Policía	7	Policía
8	Vecinos	8	Vecinos	8	Vecinos
9	ONGs	9	ONGs	9	ONGs

investigaciones mediante la agrupación de varios términos lingüísticos tampoco está considerando la no uniformidad de las escalas cualitativas. Además supone una pérdida importante de información al descartar parte de las categorías de respuesta de las escalas.

Los resultados obtenidos en este trabajo tras aplicar el procedimiento ordinal introducido recientemente por García-Lapresta y Pérez-Román [7] evidencian la importancia de no omitir información cualitativa de las escalas y considerar su no uniformidad.

AGRADECIMIENTOS

Los autores agradecen al Ministerio de Economía y Competitividad (referencia ECO2016-77900-P) y al Fondo Europeo de Desarrollo Regional (FEDER) la financiación recibida.

REFERENCIAS

- [1] M. Balinski, R. Laraki, A theory of measuring, electing and ranking. *Proceedings of the National Academy of Sciences of the United States of America* 104 (2007) 8720–8725.
- [2] Centro de Investigaciones Sociológicas. Barómetro de mayo de 2011.
- [3] Centro de Investigaciones Sociológicas. Anuario 2016.
- [4] Franceschini, F., Galetto, M., Varetto, M.: Qualitative ordinal scales: the concept of ordinal range. *Quality Engineering* 16, pp. 515-524, 2004.
- [5] García-Lapresta, J.L., González del Pozo, R., Pérez-Román, D.: Metrizable ordinal proximity measures and their aggregation, *Information Sciences*, 448-449, pp. 149-163, 2018.
- [6] García-Lapresta, J.L., Pérez-Román, D.: Ordinal proximity measures in the context of unbalanced qualitative scales and some applications to consensus and clustering. *Applied Soft Computing* 35, pp. 864-872, 2015.
- [7] García-Lapresta, J.L., Pérez-Román, D.: Aggregating opinions in non-uniform ordered qualitative scales. *Applied Soft Computing* 67, pp. 652-657, 2018.
- [8] Likert, R.: A technique for the measurement of attitudes. *Archives of Psychology* 22 (140), pp. 1-55, 1932.
- [9] Roberts, F.S.: *Measurement Theory*. Cambridge University Press., 1979.



# Monitor-While-Drilling - based estimation of rock mass rating with computational intelligence: the case of tunnel excavation front

Marta Galende  
*CARTIF Centro Tecnológico*  
 Boecillo, Valladolid, España  
 margal@cartif.es

M.J. Fuente, G.I. Sainz-Palmero  
*Dpto. Ingeniería de Sistemas y Automática*  
*Universidad de Valladolid*  
 Valladolid, España  
 mjfuente, gresai@eii.uva.es

M. Menéndez  
*VIAS y Construcciones, S.A.*  
 Avda. Camino de Santiago 50  
 28050 Madrid, España  
 manuel.menedez@vias.es

**Abstract**—The construction of tunnels has serious geomechanical uncertainties involving matters of both safety and budget. Nowadays, modern machinery gathers very useful information about the drilling process: the so-called Monitor While Drilling (MWD) data. So, one challenge is to provide support for the tunnel construction based on this *on-site* data .

Here, an MWD based methodology to support tunnel construction is introduced: a Rock Mass Rating (RMR) estimation is provided by an MWD rocky based characterization of the excavation front and expert knowledge [1].

Well-known machine learning (ML) and computational intelligence (CI) techniques are used. In addition, a collectible and “interpretable” base of knowledge is obtained, linking MWD characterized excavation fronts and RMR.

The results from a real tunnel case show a good and serviceable performance: the accuracy of the RMR estimations is high,  $Error_{test} \cong 3\%$ , using a generated knowledge base of 15 fuzzy rules, 3 linguistic variables and 3 linguistic terms.

This proposal is, however, is open to new algorithms to reinforce its performance.

**Index Terms**—Tunneling, RMR, Sofcomputing, Machine Learning, SDBR

## I. INTRODUCTION

This work is focused on the tunnelling industry, to be precise the specific case of railway tunnels, but this can be applied to other similar cases such as road tunnels; underground mining and utilities, etc. Tunnel excavation has used two main methods: *Drill & Blast* and *Tunnel Boring Machine (TBM)*. The first is the most popular excavation method for conventional tunnelling, in particular for railtrack tunnels. In any case, both methodologies involve the use of computer and control based machinery to capture and log data of different natures concerning the process: this is the so-called *Monitor or Measurement While Drilling (MWD)* data.

This work has been partially supported by the Spanish Ministry of Economy and Competitiveness and European Regional Development Fund (FEDER) through the Project no. DPI2015-67341-C2-2-R and published in *Automation in Construction*, 93C (2018) pp. 325-338, <https://doi.org/10.1016/j.autcon.2018.05.019>

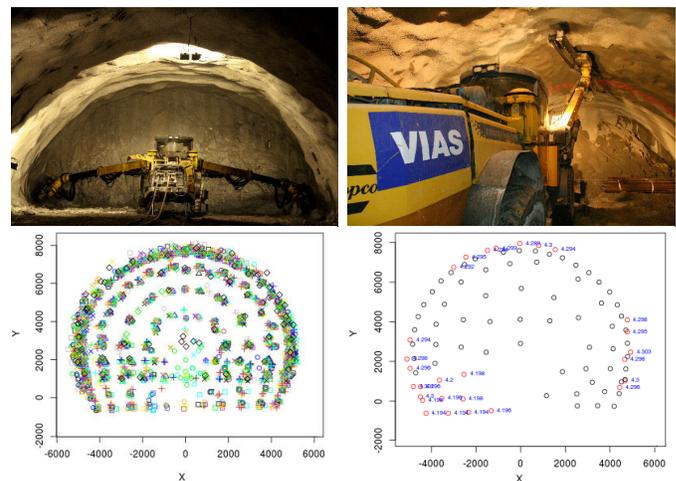


Fig. 1. Drill & Blast excavation method: excavation front and pattern of drilling holes.

## II. COMPUTATIONAL INTELLIGENCE FOR MWD AND RMR: AN APPROACH

The current proposal is based on the application of well-known computational intelligence techniques to an engineering problem concerning how available MWD data can be used during tunnel excavation to give high level support. The issues of this approach are based on ML&CI techniques, involving from data analysis to prediction and decision making, as well as the extraction of a knowledge base. Clearly and methodologically defining the stages to be dealt with in order to take advantage of the MWD data using ML&CI for the estimation of operational tunnel parameters, and how every stage can be implemented by these techniques.

In Figure 2, the general scheme of this methodology, as well as its key issues, are described. The major goal of this work is the prediction of tunnel design parameters, the current version concerns the RMR:

- 1) **Stage 1 - Unsupervised Variable Selection:** the MWD data available is processed in order to validate data, removing outliers, fixing missing values, etc. Then a

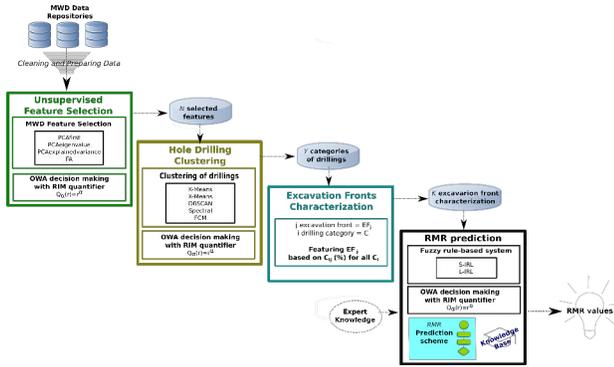


Fig. 2. Main stages of the Proposal

selection of the most relevant variables is carried out based on two well-known unsupervised techniques: PCA and FA. Finally, an OWA based multicriteria decision making is carried out to obtain an unsupervised ranking with the most relevant MWD variables to be used in the following stages.

- 2) **Stage 2 - Hole Drilling Clustering:** considering the previous MWD variable selection, different clustering algorithms and indexes are used to validate each alternative clustering or partitioning. Different categories of hole drillings are obtained and described based on the MWD variables. Once again, based on alternative clustering categories and performances, an OWA based multicriteria decision making is carried out to provide a ranking of the parameters for the clustering algorithms involved.
- 3) **Stage 3 - Characterization of Excavation Fronts:** based on the hole drilling categories obtained in the previous stage, every excavation front is characterized and summarized through its own distribution of MWD based hole drilling categories.
- 4) **Stage 4 - Prediction of RMR Values and Weightings:** based on linguistic and scatter fuzzy systems, as well as the expert knowledge collected, the prediction of the RMR values are set out. The best prediction model is based on an OWA decision making applied over all the alternative fuzzy models and their performances from different points of view, such as error, complexity or number of linguistic variables and terms. Besides, the fuzzy nature of these algorithms permits a knowledge base to be obtained, which is expressed by (linguistic) fuzzy rules, linking the MWD data with the expert knowledge available.

The *on-site* predictions and in advance, of the RMR values are extremely valuable for the technicians to manage uncertainties and plan the pattern of hole drillings for the new excavation front ahead, as well as the support needed for the tunnel walls. These estimations allow extra support to minimize risks in the advance of the tunnel.

### III. SUMMARY OF RESULTS

The open approach introduced in this paper is able to manage, on-site, the MWD data generated by the drill rig to

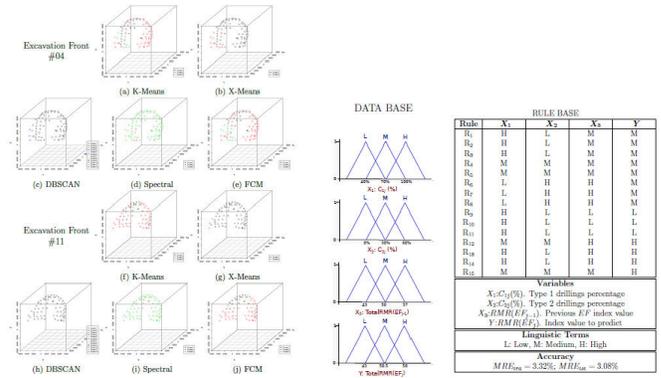


Fig. 3. Cluster based excavation front and Base of Fuzzy Rules

estimate the critical RMR value of every excavation front of the tunnel in progress. The analysis of the MWD data, on the time and frequency domain, has permitted only 3 main MWD features to be used as the basis for the rest of the methodology, meaning a huge reduction in the complexity of the solution.

This reduced number permits the drillings for a clustering procedure to be featured. In this way, every excavation front is summarized by a very few features based on these MWD drilling based rocky categories. This can be seen as a feature extraction that summarizes the characterization of every excavation front to an affordable dimensionality for ML&CI approaches. These reductions of dimensionality/complexity are critical for addressing this challenge.

Most different cluster policies, or algorithms, have shown that 2 or 3 clusters is a well-balanced number of MWD drilling based rocky categories. This fits with the knowledge and expertise concerning this issue of the technicians in charge of this type of work. This characterization has permitted the RMR value to be estimated using a linguistic and scatter FRBS: permitting the capability of both different approaches to be checked, so as to estimate the RMR while also generating a reasonable base of well-balanced fuzzy rules regarding accuracy-interpretability. This means being able to generate a good estimation and an “interpretable” knowledge base about the drilling features of every excavation front and their RMR values based on linguistic terms. This modelling has been made possible by the expert knowledge provided by geologists concerning the excavation fronts. The linguistic approach (L-IRL) has been slightly better than the scatter option (S-IRL), providing the best approach for RMR estimation as a reasonable base of knowledge:  $MRE_{tst} = 3.01\%$ , 17 fuzzy rules, 3 linguistic variables and 3 linguistic terms (Fig. 3). So the complexity of this knowledge base is affordable. Other more accurate predictions are possible,  $MRE_{tst} = 3.01\%$ , but with an increase in the complexity, 83 fuzzy rules.

### REFERENCES

- [1] M. Galende, M. M.J. Fuente, G. Sainz-Palmero, M. Menéndez, Monitor-while-drilling - based estimation of rock mass rating with computational intelligence: the case of tunnel excavation front, *Automation in Construction* (93C) (2018) 325–338. doi:https://doi.org/10.1016/j.autcon.2018.05.019.



# Nuevo Módulo de Conexión Inalámbrico vía Bluetooth con Arduino en la Librería JFML

Francisco Jesús Arcos  
Dpt. de Ciencias de la Computación e I.A.  
Universidad de Granada  
18071 Granada, España  
Email: pacoarcos82@gmail.com

José Manuel Soto-Hidalgo  
Dpt. de Electrónica y Tecnología Electrónica  
Universidad de Córdoba  
14071 Córdoba, España  
Email: jmsoto@uco.es

Autilia Vitiello  
Dpt. de Ciencias de la Computación  
Universidad de Salerno  
84084 Salerno, Italia  
Email: avitiello@unisa.it

Giovanni Acampora  
Dpt. de Física Ettore Pancini  
Universidad de Nápoles Federico II  
80126 Nápoles, Italia  
Email: giovanni.acampora@unina.it

Jesús Alcalá-Fdez  
Instituto de Investigación DaSCI  
Universidad de Granada  
18071 Granada, España  
Email: jalcala@decsai.ugr.es

**Resumen**—Los Sistemas Basados en Reglas Difusas han sido aplicados con éxito en un amplio rango de aplicaciones reales. Recientemente, la IEEE publicó el estándar IEEE Std 1855<sup>TM</sup>-2016 para proporcionar a la comunidad una herramienta única y bien definida que permita diseñar sistemas completamente independiente del hardware/software específico. La librería Java Fuzzy Markup Language es la primera herramienta software de código abierto que ofrece una implementación completa de dicho estándar. Sin embargo, la versión actual de esta librería no permite conectarse a sistemas embebidos, lo que dificulta la aplicación de los sistemas difusos a problemas de control. El objetivo de este trabajo es desarrollar un nuevo módulo que permita diseñar y ejecutar un controlador difuso en el sistema embebido Arduino vía Bluetooth. Para ilustrar el potencial de este módulo se ha desarrollado un caso de uso en el que se utiliza un controlador difuso para manejar un robot móvil para el comportamiento de seguimiento de contornos.

**Index Terms**—Sistemas Basados en Reglas Difusas, JFML, Arduino, Software de Código Abierto, Hardware Libre

## I. INTRODUCCIÓN

Los Sistemas Basados en Reglas Difusas (SBRD) [1] han sido aplicados con éxito en múltiples campos, tales como clasificación [2], regresión [3], control [4], etc., debido a su capacidad para incluir conocimiento experto a priori, manejar la imprecisión existente en los datos, y representar sistemas para los que no es posible obtener un modelo matemático por la tipología del problema y de los datos. En concreto, los controladores difusos son un modelo específico de SBRDs que permite controlar sistemas complejos de una manera similar a como lo hace un humano.

Para poder hacer uso de estos controladores en muchos problemas reales es necesario que puedan ser ejecutados en sistemas embebidos y conectados con un conjunto de sensores/actuadores. Los sistemas embebidos son dispositivos integrados diseñados para realizar una o unas pocas funciones

específicas. En este escenario, es crucial poder integrar SBRDs en sistemas embebidos específicos.

Recientemente, la IEEE Computational Intelligence Society (IEEE-CIS) ha patrocinado la publicación del nuevo estándar para SBRD (IEEE Std 1855<sup>TM</sup>-2016) [5] en el que se define el lenguaje Fuzzy Markup Language (FML) [6] basado en W3C eXtensible Markup Language (XML). El objetivo de este estándar es proporcionar a la comunidad una herramienta única y bien definida que permite un diseño del sistema completamente independiente del hardware/software específico.

Para que el estándar IEEE sea operativo y útil para la comunidad, se ha desarrollado la librería Java Fuzzy Markup Language (JFML)<sup>1</sup> de código abierto que ofrece una implementación completa del estándar. Sin embargo, la versión actual de la librería JFML no permite conectarse a dispositivos embebidos, lo que dificulta la aplicación de los SBRDs diseñados a problemas reales (centralizados o distribuidos). Aunque algunas librerías permiten utilizar SBRDs en algunos dispositivos hardware, tales como Matlab para Arduino<sup>2</sup> o eFLL<sup>3</sup>, actualmente no existe una infraestructura software de código abierto que soporte SBRD diseñados según el estándar IEEE 1855<sup>TM</sup>-2016 [7]. Además, en general, estas implementaciones se basan en aproximaciones reducidas de la lógica difusa que se ejecutan en el microcontrolador del dispositivo embebido, limitando su capacidad de cálculo.

El objetivo principal de este trabajo es desarrollar un módulo de código abierto para la librería JFML que permita diseñar y ejecutar SBRD en Arduino [8], uno de los sistemas embebidos más conocidos y utilizados en el modelo de hardware libre [9]. Con este módulo, los sensores/actuadores pueden ser asignados a las variables lingüísticas de la base de conocimiento permitiendo un diseño completamente independiente de las

Este trabajo está soportado por el Ministerio de Economía y Competitividad bajo el proyecto TIN2014-57251-P y el Ministerio de Economía, Industria y Competitividad TIN2017-89517-P.

<sup>1</sup><https://github.com/sotillo19/JFML>

<sup>2</sup><http://playground.arduino.cc/Interfacing/Matlab>

<sup>3</sup><https://github.com/zerokol/eFLL>

restricciones específicas de hardware/software que caracterizan la arquitectura dada en la cual se despliega el sistema. Además, se ha definido un nuevo protocolo de comunicación vía Bluetooth entre JFML y Arduino que permite realizar las inferencias en el ordenador en que se encuentra instalado el núcleo de JFML, eliminando así la limitada capacidad de computación que ofrecen los sistemas embebidos. Para ilustrar el potencial de este módulo mostramos un caso de uso con un controlador difuso para manejar un robot móvil en el comportamiento de seguimiento de contornos. En particular, mostramos cómo el nuevo módulo de JFML puede usarse para implementar SBRDs en Arduino de una manera fácil y lista para ser ejecutada sin ninguna programación adicional de Arduino. Como resultado, el nuevo módulo permite la interoperabilidad total en el diseño de SBRDs con placas Arduino.

Este trabajo está organizado de la siguiente manera. La sección II presenta una breve introducción del sistema embebido Arduino e introduce la librería JFML y sus principales características. La sección III describe el nuevo módulo de JFML para sistema embebido Arduino. La sección IV muestra un caso de uso centrado en cómo se puede utilizar el nuevo módulo para ejecutar un controlador difuso para el seguimiento de contornos de un robot móvil. Por último, en la sección V se indican algunas observaciones finales y trabajos futuros.

## II. PRELIMINARES

Esta sección pone en contexto los SBRDs, introduce el sistema embebido Arduino así como la librería Java de código abierto JFML.

### II-A. Sistemas Basados en Reglas Difusas (SBRDs)

La mayoría de las aplicaciones reales en el ámbito de sistemas control tienen en común diversas características que hacen difícil el modelado del sistema utilizando las estrategias clásicas de modelado. Por ejemplo, en sistemas donde los procesos se describen de forma imprecisa sin recurrir a modelos matemáticos o algoritmos de los procesos físicos involucrados. En estos casos, la lógica difusa representa una poderosa herramienta con la que poder diseñar modelos precisos en sistemas complejos donde, debido a la complejidad o la imprecisión, las herramientas clásicas no tienen éxito.

En áreas de investigación como economía, procesamiento de imágenes, etc., se han aplicado con éxito los sistemas difusos [10], [11]. No obstante, posiblemente el control difuso sea el ámbito de aplicación más común de la lógica difusa donde un gran número de publicaciones lo avalan [12]–[14]. Estos sistemas, llamados SBRDs, constan de: una Base de Conocimiento (BC) que contiene las particiones difusas y el conjunto de reglas que modelan el sistema; una interfaz de Fuzzificación que transforma los valores entrada nítidos en conjuntos difusos; un sistema de Inferencia Difusa que realiza el razonamiento difuso haciendo uso de los valores de entrada y de la BC; y la interfaz de Defuzzificación que transforma la salida difusa de la inferencia en valores nítidos.

### II-B. Sistemas embebidos: Arduino

Un sistema embebido es una pieza de hardware fuertemente especializada para un propósito específico que es embebido como parte de un dispositivo completo [15]. Dado que se dedican a tareas específicas, los ingenieros pueden optimizarlas para reducir el tamaño y el coste del producto y aumentar la fiabilidad y el rendimiento. Debido a esto, en los últimos años la industria del hardware ha experimentado un crecimiento exponencial y los sistemas embebidos controlan muchos de los dispositivos de uso común en la actualidad. Se estima que el 98 % de todos los microprocesadores se fabrican como parte de un sistema embebido.

Uno de los sistemas embebidos más conocidos y utilizados en el modelo de hardware libre es Arduino [8]. Es una tarjeta microcontroladora que contiene un conjunto de pines de entrada/salida digitales y analógicos que permiten conectarla a varias tarjetas de expansión y componentes electrónicos (antenas Bluetooth o Wifi, sensores, actuadores, entre otros), y su microcontrolador se puede programar utilizando un dialecto de los lenguajes de programación C y C++ (archivos con extensión *.ino*). Debido a su gran simplicidad y usabilidad es una herramienta popular para el desarrollo de productos de Internet of Things, así como una de las herramientas más exitosas para la educación STEM/STEAM<sup>4</sup>. Por ejemplo, en [16] se propuso el diseño de un robot móvil de bajo coste basado en Arduino como herramienta educativa alternativa o complementaria en laboratorios, aulas, e-learning y cursos abiertos masivos online (MOOC); Khater et al. [17] presentaron un controlador difuso adaptativo basado en Arduino DUE para gestionar un motor de corriente continua con eje flexible; etc.

### II-C. Librería Java Fuzzy Markup Language

En el año 2000, el Fuzzy Control Language (FCL) fue definido en la norma IEC61131-7 de la Comisión Electrotécnica Internacional [18] con el objetivo de proporcionar a los ingenieros con una herramienta común y bien definida para integrar SBRDs en problemas de control, facilitando el intercambio de controladores entre diferentes lenguajes de programación y software (aumentando la usabilidad del software disponible). Recientemente, la IEEE-CIS patrocinó la publicación del estándar IEEE Std 1855<sup>TM</sup>-2016 [19] en el que definen el lenguaje FML basado en W3C XML para extender estas ventajas a otros tipos de problemas (por ejemplo, clasificación o regresión), y para hacer uso de las ventajas XML para representar SBRDs.

JFML es una librería Java de código abierto (Licencia Pública GNU GPLv3)<sup>5</sup> para diseñar y usar SBRDs de acuerdo al estándar IEEE 1855<sup>TM</sup>-2016. Esta librería incluye los 4 sistemas de inferencia (Mamdani, TSK, Tsukamoto y AnYa) y todas las funciones de pertenencia (MFs), operadores difusos, etc., considerados en la definición de esquema XML (XSD) del estándar (ver [19] para más información). JMFL incluye métodos personalizados (nombrados según el patrón

<sup>4</sup><http://stemtosteam.org/>

<sup>5</sup><https://github.com/sotillo19/JFML>



*custom\_name*) para todos los elementos indicados en el XSD que permiten ampliar la librería de acuerdo con el estándar sin necesidad de modificar la gramática del lenguaje (por ejemplo, con MFs tipo 2 o intuitivo). Además, esta librería utiliza la misma estructura de árbol etiquetada que el estándar, lo que facilita la integración de cambios futuros del estándar. JFML hace uso de la nueva API de Java JAXB para proporcionar una forma rápida y conveniente de leer y escribir SBRDs de acuerdo al estándar. Además, para facilitar la interoperabilidad de la librería con otros software disponibles, JFML incluye un módulo para importar/exportar SBRDs desde documentos FCL, PMML y fis (sistemas diseñados con la Toolbox de lógica difusa de Matlab). Una amplia documentación sobre la librería junto con una buena variedad de ejemplos puede encontrarse en la página web <sup>6</sup>.

### III. MÓDULO PARA ARDUINO VÍA BLUETOOTH

En esta sección presentamos el nuevo módulo para conectar JFML con Arduino vía Bluetooth. La subsección III-A muestra una visión general del diagrama de clases principal del módulo. La subsección III-B describe el protocolo de comunicación vía Bluetooth para la comunicación bidireccional entre JFML y Arduino. Y finalmente, el diagrama de clases para el sistema embebido Arduino y el conjunto de sensores/actuadores incluidos en el módulo son presentados en la subsección III-C.

#### III-A. Diseño General

A continuación, se introducen las principales clases que compone el nuevo módulo con el objetivo de proporcionar una visión general de las posibilidades que ofrecen.

1. *EmbeddedSystem*: Es la clase principal responsable de definir las características y el tipo de conexión con Arduino. Requiere un nombre, un puerto serie y una velocidad de transmisión para establecer la conexión con el núcleo JFML. Tiene asociada una lista de objetos *EmbeddedVariable* que representa la relación entre las variables de la base de conocimiento y los sensores/actuadores. Además, esta clase define un método abstracto para crear un archivo ejecutable de acuerdo con los requisitos de diseño de la arquitectura de Arduino. Gracias a este archivo, un usuario puede ejecutar fácilmente un SBRD sin necesidad de tener conocimientos específicos sobre la arquitectura y el lenguaje de programación de Arduino.

2. *EmbeddedController*: Esta clase permite coordinar todas las placas Arduino conectadas a JFML. Para ello contiene una lista de objetos *EmbeddedSystem* y un objeto de la clase *FuzzyInferenceSystem* para determinar el tipo de inferencia difusa considerada. Además, esta clase permite al usuario indicar si el sistema debe funcionar durante un periodo de tiempo fijo o de forma indefinidamente.

3. *EmbeddedVariable*: Esta clase representa la relación entre los sensores/actuadores y las variables de la base de conocimiento, indicando para cada uno de ellos el puerto de entrada/salida asociado. Destacar que el dominio de los sensores/actuadores y de las variables son escalados para que haya una relación directa entre los dominios.

4. *Sensor* y *SensorLibrary*: Estas clases son las encargadas de definir las características de los diferentes sensores/actuadores, incluyendo: el tipo (analógico o digital), el dominio (valor máximo y mínimo), y una librería de operaciones específicas. Destacar que cada sensor/actuador tiene asociada una librería con los códigos de operaciones asociados al mismo (código de inicialización, etc.).

5. *AggregatedSensor*: Esta clase permite definir un nuevo tipo de sensor que genera información útil para el SBRD a partir de los valores proporcionados por uno o varios objetos de la clase *Sensor*. Destacar que esta clase también puede ser utilizada sin objetos de la clase *Sensor* para generar una entrada del controlador mediante una función, variable o constante que no requiera el valor de los sensores de entrada.

6. *Connection* y *ConnectionLibrary*: La clase *Connection* especifica un método de conexión bidireccional que permite conectar Arduino con el núcleo de JFML, definiendo un protocolo de comunicación entre ellos. La clase *ConnectionLibrary* permite incluir un código adicional para conectar las placas Arduino si es necesario. En la siguiente subsección se mostrará en detalle el protocolo de comunicación diseñado.

#### III-B. Protocolo de Comunicación

El nuevo módulo permite que la inferencia se realice en el ordenador en el que esté instalado el núcleo de JFML, evitando que se tenga que realizar en el sistema embebido que normalmente tiene menor capacidad computacional y de memoria. Para ello, se ha definido un nuevo protocolo de comunicación entre JFML y Arduino tanto para la conexión como para el intercambio de mensajes entre ambos. Este protocolo realiza la gestión de la comunicación mediante peticiones de mensajes de lectura/escritura que consta de los siguientes pasos:

Primero, el controlador (clase *EmbeddedController*) envía un mensaje de difusión a todas las placas Arduino para establecer la conexión con JFML. Cada Arduino recibe un mensaje de lectura y/o escritura de los valores de los sensores conectados en función de la relación establecida entre los sensores y las variables de la base de conocimiento. Por ejemplo, si un sensor está asociado a una variable de entrada, el sistema embebido obtiene un valor del sensor. Sin embargo, si el sensor/actuador se asocia a una variable de salida, el sistema embebido establece un valor para el sensor. Este valor se envía a JFML como un mensaje según la definición del protocolo.

Segundo, el controlador espera una respuesta (un mensaje con el valor de los sensores) de todas las placas Arduino conectadas. Si el controlador recibe respuesta de todos ellos y no se supera el tiempo de espera definido, los valores de las variables de la base de conocimiento se actualizan con los valores recibidos (procedentes de los sensores). En caso contrario se muestra un mensaje de error.

Tercero, JFML hace la inferencia difusa teniendo en cuenta los valores de las variables de entrada. Posteriormente, los valores de salida se envían a las placas de Arduino correspondientes (aquellas que tienen sensores asociados con variables

<sup>6</sup><http://www.uco.es/JFML>

de salida). Los actuadores asociados a las variables de salida se ajustan de acuerdo con los resultados de la inferencia difusa. Finalmente, el controlador espera una respuesta ACK de todos los Arduinos indicando que los resultados de la inferencia difusa están correctamente configurados en los sensores o actuadores correspondientes, de lo contrario, aparece un mensaje de error.

### III-C. Diseño de Clases para el Sistema Embebido Arduino

Se lleva a cabo una implementación basada en Arduino de acuerdo con el diagrama de clases introducido en la subsección III-A. Para ello se implementa una nueva clase *EmbeddedSystemArduino* que extiende a la clase abstracta *EmbeddedSystem*. Además, también se desarrolla una comunicación bidireccional por el puerto Bluetooth para que las placas Arduino puedan conectarse y usarse para diseñar SBRDs de forma sencilla.

La clase *EmbeddedSystemArduino* implementa el método abstracto para crear automáticamente un archivo ejecutable (.ino) de acuerdo con el diseño de la arquitectura de Arduino. Este archivo .ino incluirá el código necesario para iniciar y ejecutar el sistema en la placa Arduino. Requiere dos funciones: *setup()* y *loop()*. La función *setup()* es ejecutada cuando la placa Arduino es encendida o se ha utilizado la opción reset. Principalmente es utilizada para inicializar variables, los modos de los pines de entrada y salida, e inicializar otras librerías necesarias en el programa. La función *loop()* es ejecutada después de la función *setup()* dentro de un bucle en el programa principal. Esta función incluye el código necesario para leer y actualizar constantemente el valor de los sensores y actuadores. El método abstracto incluye en el código de la función *setup()* las variables de la base de conocimiento que está asociada con un sensor o actuador (además de las bibliotecas asociadas), el modo de cada una (entrada o salida), y el número del pin al que está conectado. Además, este método incluye en la función *loop()* el código necesario mantener la comunicación entre JFML y la placa Arduino. El fichero .ino generado automáticamente debe ser cargado directamente en la ROM de Arduino mediante la IDE de la empresa. Destacar que este fichero puede ser modificado por el usuario para incluir su propio código si es necesario.

Este módulo también incluye una colección de los sensores y actuadores más utilizados en las propuestas con Arduino [20]. Además, los usuarios pueden añadir nuevos sensores y/o actuadores fácilmente extendiendo la clase *Sensor*. El cuadro I muestra una lista con los 7 sensores y los 5 actuadores integrados en el módulo.

## IV. CASO DE USO

Con el objetivo de mostrar el potencial del nuevo módulo de JFML, se ha realizado un caso de uso con un SBRD para controlar un robot móvil para el comportamiento de seguimiento de contornos. En robótica móvil, los controladores difusos son comúnmente considerados para realizar este comportamiento que es muy utilizado para explorar estancias interiores desconocidos. El objetivo es mantener una distancia adecuada entre el robot y la pared ( $d_{wall}$ ) mientras el robot se

Cuadro I  
SENSORES Y ACTUADORES INCLUIDOS EN EL MÓDULO

Sensor	Tipo	Digital	Analógico
DHT22	Temperatura y Humedad	X	
HC-SR04	Distancia (ultrasonido)	X	
HC-SR501	Movimiento	X	
LDR	Intensidad lumínica	X	X
MPU6050	Acelerómetro y Giroscopio	X	
MQ-2	Gas	X	X
H206	Encoder	X	
Actuador	Tipo	Digital	Analógico
DC Motor	Motor corriente continua	X	X
L298N	Driver	X	X
LED Color	Led	X	
LED PWM	Led	X	
SG90 Motor	Servo motor		X

mueve lo más rápido posible, evitando cambios bruscos en los movimientos y en la velocidad. En [21], los autores diseñaron un controlador difuso para seguimiento de contornos para el robot Nomad-200 haciendo uso de algoritmos genéticos. Éste consta de cuatro variables de entrada: relación entre la distancia a la derecha y  $d_{wall}$  ( $RD$ ), relación entre la distancia a la izquierda y de la derecha ( $DQ$ ); orientación respecto a la pared ( $O$ ); y velocidad lineal respecto a la velocidad lineal máxima del robot ( $V$ ); y dos variables de salida: aceleración lineal ( $LA$ ) y velocidad angular ( $AV$ ) respecto a la aceleración lineal máxima y velocidad angular del robot, respectivamente. Este controlador difuso está disponible como uno de los ejemplos proporcionados con el software JFML (*./Ejemplos/XMLFiles/RobotMamdani.xml*).

Para este caso de uso montamos un robot móvil con componentes de bajo coste que consta de una placa Arduino MEGA 2560, cinco sensores de distancia HC-SR04, dos sensores de velocidad del motor H206, un sensor acelerómetro/gyroscopio MPU6050, y dos motores de corriente continua con el conductor H-Bridge L298N (ver Figura 1). El robot móvil es controlado en tiempo real desde el ordenador portátil utilizando la librería JFML para ejecutar el controlador difuso y gestionar la comunicación con los sensores/actuadores vía Bluetooth. Destacar que los valores de los sensores no se utilizan directamente como entradas del controlador difuso. Varios objetos de la clase *Aggregated Sensor* son utilizados para generar los valores de entrada del controlador a partir de los valores obtenidos de distintos sensores. Asimismo, las salidas del controlador se envían a otros objetos de la clase *Aggregated Sensor* para generar los valores de los motores.

Para llevar a cabo todo el proceso, es necesario realizar los siguientes pasos. El primer paso es leer el controlador difuso desde el documento FML. El segundo paso es crear los sensores/actuadores que están conectados con la placa Arduino. El tercer paso es generar los objetos de la clase *Aggregated Sensor* para los valores de entrada y salida. El cuarto paso es mapear las variables de entrada/salida con los sensores/actuadores e incluirlas en una lista. El quinto paso es crear el sistema embebido (incluyendo el nombre, puerto, etc.) y generar el archivo .ino. Estos pasos implementan con

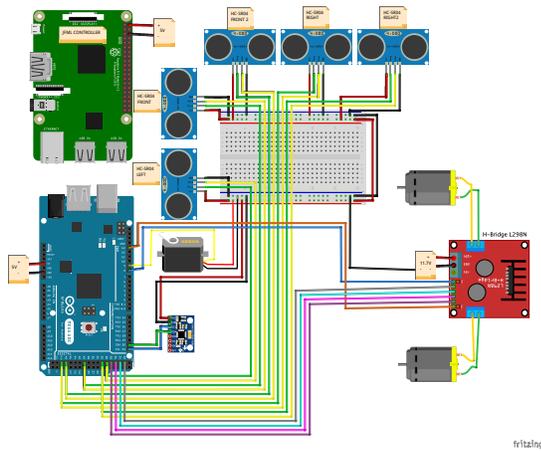


Figura 1. Arquitectura Hardware del Robot Movil.

siguiente código Java:

```
// Paso 1: Lectura del controlador desde un fichero FML
File fml = new File("./Examples/XMLFiles/RobotMamdani.xml");
FuzzyInferenceSystem fs = JFML.load(fml);

// Paso 2: Crear los sensores/actuadores
KnowledgeBaseVariable var_rd = fs.getVariable("rd");
KnowledgeBaseVariable var_dq = fs.getVariable("dq");
KnowledgeBaseVariable var_o = fs.getVariable("o");
KnowledgeBaseVariable var_v = fs.getVariable("v");
KnowledgeBaseVariable var_la = fs.getVariable("la");
KnowledgeBaseVariable var_av = fs.getVariable("av");

Sensor rd_front = new ArduinoHC_SR04(rd.getName()+"front",
ArduinoPin.PIN_40, ArduinoPin.PIN_41, 10, 200, true, 3,
true, true);
Sensor rd_front2 = new ArduinoHC_SR04(rd.getName()+"front2",
ArduinoPin.PIN_48, ArduinoPin.PIN_49, true, 3, false, true);
Sensor rd_right = new ArduinoHC_SR04(rd.getName()+"right",
ArduinoPin.PIN_50, ArduinoPin.PIN_51, true, 3, false, true);
Sensor rd_right2 = new ArduinoHC_SR04(rd.getName()+"right2",
ArduinoPin.PIN_32, ArduinoPin.PIN_33, true, 3, false, true);
Sensor dq_left = new ArduinoHC_SR04(dq.getName()+"left",
ArduinoPin.PIN_30, ArduinoPin.PIN_31, true, 3, false, true);
Sensor angular_velocity = new ArduinoSERVO(av.getName(),
ArduinoPin.PIN_9, -1, 1, 45, 135, 45, true);
Sensor linear_acceleration = new ArduinoH_BRIDGE_L298N(
la.getName(), ArduinoPin.PIN_6, ArduinoPin.PIN_7,
ArduinoPin.PIN_4, ArduinoPin.PIN_2, ArduinoPin.PIN_1,
ArduinoPin.PIN_5, -1, 1, 40, 70, 15);
Sensor orientation = new ArduinoMPU6050(o.getName(), -45,
45, true);

// Paso 3: Crear los sensores agregados
ArrayList<Sensor> sensorsRD = new ArrayList<>();
sensorsRD.add(rd_front);
sensorsRD.add(rd_front2);
sensorsRD.add(rd_right);
sensorsRD.add(rd_right2);
AggregatedSensor rdSensor = new ArduinoAggregatedSensorRD(
rd.getName(), sensorsRD, 0, 3, 6, 50, true);
ArrayList<Sensor> sensorsDQ = new ArrayList<>();
sensorsDQ.add(dq_left);
AggregatedSensor dqSensor = new ArduinoAggregatedSensorDQ(
dq.getName(), sensorsDQ, 0, 2);
ArrayList<Sensor> sensorsO = new ArrayList<>();
sensorsO.add(rd_right);
sensorsO.add(rd_right2);
AggregatedSensor OSensor = new ArduinoAggregatedSensorO(
o.getName(), sensorsO, -45, 45);
ArrayList<Sensor> sensorsAV = new ArrayList<>();
sensorsAV.add(angular_velocity);
AggregatedSensor avSensor = new ArduinoAggregatedSensorAV(
av.getName(), sensorsAV, -1, 1, 18);
AggregatedSensor vSensor = new ArduinoAggregatedSensorV(
v.getName(), -1, 1, 50);
```

```
// Paso 4: Mapeo de los sensores/actuadores
ArrayList<EmbeddedVariable> embVar =
new ArrayList<>();
embVar.add(new EmbeddedVariableArduino(0, rd, rd_front));
embVar.add(new EmbeddedVariableArduino(0, rd, rd_front2));
embVar.add(new EmbeddedVariableArduino(0, rd, rd_right));
embVar.add(new EmbeddedVariableArduino(0, rd, rd_right2));
embVar.add(new EmbeddedVariableArduino(0, rd, rdSensor));
embVar.add(new EmbeddedVariableArduino(1, dq, dq_left));
embVar.add(new EmbeddedVariableArduino(1, dq, dqSensor));
embVar.add(new EmbeddedVariableArduino(2, o, orientation));
embVar.add(new EmbeddedVariableArduino(2, o, OSensor));
embVar.add(new EmbeddedVariableArduino(3, v, vSensor));
embVar.add(new EmbeddedVariableArduino(4, la,
linear_acceleration));
embVar.add(new EmbeddedVariableArduino(5, av,
angular_velocity));
embVar.add(new EmbeddedVariableArduino(5, av, avSensor));

// Paso 5: Crear el sistema embebido y el fichero .ino
EmbeddedSystem robot = new EmbeddedSystemArduino
("RobotMamdani", "/dev/ttyACM0", 2000000, embVar);
robot.createRunnableEmbeddedFile("./Examples/Arduino/
RobotMamdani.ino");
```

Una vez creado el archivo *.ino*, éste se escriben en el microcontrolador de la placa Arduino mediante la IDE proporcionado por la empresa y se establece la conexión Bluetooth con el portátil. Finalmente, el sistema embebido se asocia al controlador difuso y se ejecuta el programa. Para realizar este paso se utiliza el siguiente código Java:

```
ArrayList<EmbeddedSystem> arduinos = new ArrayList<>();
arduinos.add(robot);

EmbeddedController controller = new EmbeddedControllerSystem(
arduinos, fs);
controller.run(1000);
```

Destacar que el sistema embebido es añadido a una lista porque podríamos utilizar varias placas de Arduino para utilizar los sensores/actuadores. Las pruebas fueron realizadas en la planta baja del Centro de Investigación en Tecnologías de la Información y las Comunicaciones de la Universidad de Granada (CITIC-UGR) que incluye diferentes situaciones a las que el robot se enfrenta habitualmente durante la navegación: paredes rectas de diferentes longitudes, esquinas cóncavas y convexas, etc., cubriendo así una amplia gama de contornos. La distancia máxima deseada en este caso fue de 50 cm. La Figura 2 muestra la trayectoria del robot mediante marcas rojas circulares. Podemos ver cómo el robot presenta un buen comportamiento a pesar de que las medidas de los sensores de ultrasonidos son bastante ruidosas debido a que los pasillos tienen adoquines en las paredes y las puertas son de madera. Para este entorno el robot registro una distancia media de 50,5 cm con una desviación típica de 3 cm y una velocidad media de 42,9 cm/s.

## V. CONCLUSIONES

En este trabajo presentamos un nuevo módulo Java de código abierto para la librería JFML que permite conectar fácilmente un SBRD con uno de los sistemas embebidos más utilizados en el modelo de hardware abierto, Arduino. Este módulo permite asociar las variables de entrada/salida de un SBRD con sensores/actuadores a través de una placa Arduino. Además, este módulo integra un protocolo de comunicación vía Bluetooth entre JFML y las placas Arduino

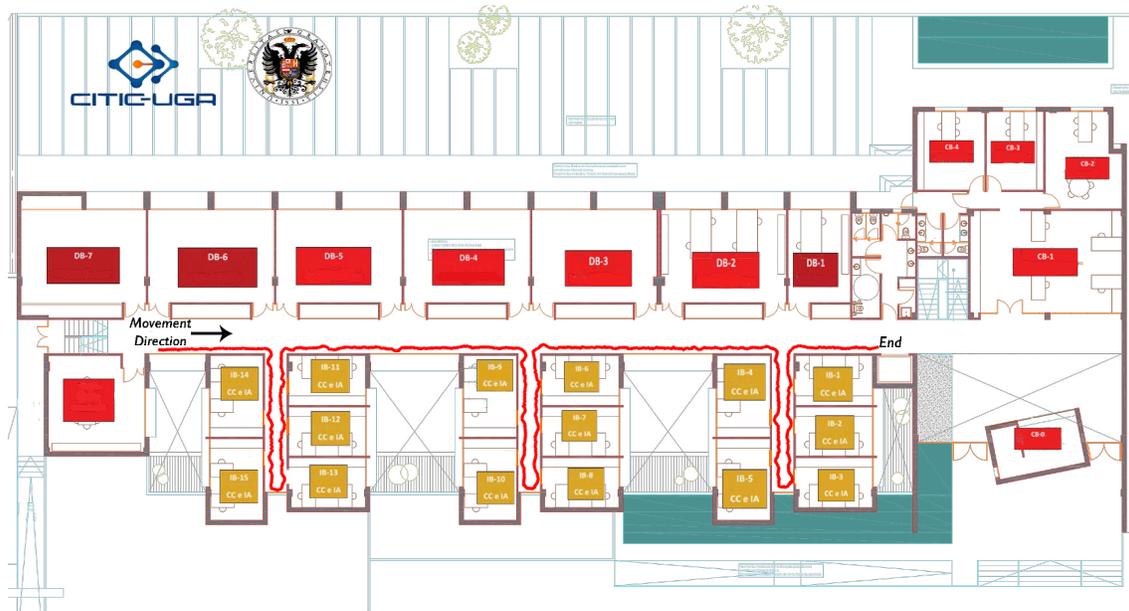


Figura 2. Entorno de prueba

que permite realizar la inferencia difusa en un ordenador externo, eliminando la limitada capacidad de cálculo que ofrecen los sistemas embebidos. Para ilustrar el potencial del nuevo módulo hemos mostrado un caso de estudio con un controlador difuso definido según IEEE Std 1855<sup>TM</sup>-2016 para controlar un robot móvil para seguimiento de contornos. Se ilustra el uso del nuevo módulo en un breve programa Java donde las variables de entrada/salida del controlador se asocian con los sensores de distancia y los motores, se genera el archivo *.ino* para el microcontrolador de la placa Arduino, y se gestiona el robot realizando la inferencia difusa desde un ordenador externo manteniendo la comunicación vía Bluetooth. Actualmente se está trabajando en la incorporación de nuevos sensores y actuadores al módulo y en el desarrollo de un mecanismo de comunicación Wifi.

#### REFERENCIAS

- [1] E. Trillas and L. Eciolaza, *Fuzzy Logic: An Introductory Course for Engineering Students*. Springer, 2015.
- [2] J. Alcalá-Fdez, R. Alcalá, S. González, Y. Nojima, and S. García, "Evolutionary fuzzy rule-based methods for monotonic classification," *IEEE Transactions on Fuzzy Systems*, vol. 25, no. 6, pp. 1376–1390, 2017.
- [3] H. Zuo, G. Zhang, W. Pedrycz, V. Behbood, and J. Lu, "Fuzzy regression transfer learning in takagi-sugeno fuzzy models," *IEEE Transactions on Fuzzy Systems*, vol. 25, no. 6, pp. 1795–1807, 2017.
- [4] Y. Li, S. Sui, and S. Tong, "Adaptive fuzzy control design for stochastic nonlinear switched systems with arbitrary switchings and unmodeled dynamics," *IEEE Transactions on Cybernetics*, vol. 47, no. 2, pp. 403–414, 2017.
- [5] G. Acampora, B. di Stefano, and A. Vitiello, "IEEE 1855<sup>TM</sup>: The first IEEE standard sponsored by IEEE Computational Intelligence Society," *IEEE Computational Intelligence Magazine*, vol. 11, no. 4, pp. 4–7, 2016.
- [6] G. Acampora, "Fuzzy Markup Language: a XML based language for enabling full interoperability in fuzzy systems design," in *On the Power of Fuzzy Markup Language*, G. Acampora, V. Loia, C.-S. Lee, and M.-H. Wang, Eds. Springer, Berlin, 2013, pp. 17–31.
- [7] J. Alcalá-Fdez and J. M. Alonso, "A survey of fuzzy systems software: Taxonomy, current research trends and prospects," *IEEE Transactions on Fuzzy Systems*, vol. 24, no. 1, pp. 40–56, 2016.
- [8] Arduino. (2017) Open-source electronic prototyping platform enabling users to create interactive electronic objects.
- [9] J. Pearce, *Open-Source Lab: How to Build Your Own Hardware and Reduce Research Costs*. Elsevier, 2013.
- [10] M. Muñoz, E. Miranda, and P. Sánchez, "A fuzzy system for estimating premium cost of option exchange using mamdani inference: Derivatives market of mexico," *International Journal of Computational Intelligence Systems*, vol. 10, no. 1, pp. 153–164, 2017.
- [11] A. Fahmi, K. Ulengin, and C. Kahraman, "Analysis of brand image effect on advertising awareness using a neuro-fuzzy and a neural network prediction models," *International Journal of Computational Intelligence Systems*, vol. 10, no. 1, pp. 690–710, 2017.
- [12] H. Zermane and H. Mouss, "Internet and fuzzy based control system for rotary kiln in cement manufacturing plant," *International Journal of Computational Intelligence Systems*, vol. 10, no. 1, pp. 835–850, 2017.
- [13] L. Tang and J. Zhao, "Adaptive tracking control for discrete-time switched nonlinear systems with dead-zone inputs," *Fuzzy Sets and Systems*, vol. 344, pp. 51–69, 2018.
- [14] B. Zhang, C. Yang, H. Zhu, P. Shi, and W. Gui, "Controllable-domain-based fuzzy rule extraction for copper removal process control," *IEEE Transactions on Fuzzy Systems*, vol. 26, no. 3, pp. 1744–1756, 2018.
- [15] M. Barr, "Embedded systems glossary," *Neutrino Technical Library*, retrieved 2007-04-21.
- [16] F. López-Rodríguez and F. Cuesta, "Andruino-A1: Low-cost educational mobile robot based on android and arduino," *Journal of Intelligent & Robotic Systems*, vol. 81, no. 1, pp. 63–76, 2016.
- [17] A. A. Khater, M. El-Bardini, and N. M. El-Rabaie, "Embedded adaptive fuzzy controller based on reinforcement learning for dc motor with flexible shaft," *Arabian Journal for Science and Engineering*, vol. 40, no. 8, pp. 2389–2406, 2015.
- [18] *International Electrotechnical Commission technical committee industrial process measurement and control. IEC 61131 - Programmable Controllers*. IEC, 2000.
- [19] IEEE-SA Standards Board, "IEEE standard for fuzzy markup language," *IEEE Std 1855-2016*, pp. 1–89, 2016.
- [20] K. Karvinen and T. Karvinen, *Getting Started with Sensors: Measure the World with Electronics, Arduino, and Raspberry Pi*. Maker Media, Incorporated, 2014.
- [21] M. Mucientes, R. Alcalá, J. Alcalá-Fdez, and J. Casillas, "Learning weighted linguistic rules to control an autonomous robot," *International Journal of Intelligent Systems*, vol. 24, no. 3, pp. 226–251, 2009.



# Un algoritmo de comparación de imágenes basado en funciones de semejanza de matrices

Mikel Sesma-Sara<sup>\*†</sup>, Laura De Miguel<sup>\*†</sup>, Javier Fernandez<sup>\*†</sup>,  
Eduarne Barrenechea<sup>\*†</sup>, Radko Mesiar<sup>‡§</sup>, y Humberto Bustince<sup>\*†</sup>

<sup>\*</sup>Departamento de Estadística, Informática y Matemáticas  
Universidad Pública de Navarra, 31006 Pamplona, Spain

Email: {mikel.sesma,laura.demiguel,fcojavier.fernandez,eduarne.barrenechea,bustince}@unavarra.es

<sup>†</sup>Institute of Smart Cities, Universidad Pública de Navarra, 31006 Pamplona, Spain

<sup>‡</sup>Department of Mathematics and Descriptive Geometry, Faculty of Civil Engineering,  
Slovak University of Technology, Radlinského 11, Bratislava, Slovakia

Email: mesiar@math.sk

<sup>§</sup>Institute for Research and Applications of Fuzzy Modelling,  
University of Ostrava, 30. dubna 22, Ostrava 1, Czech Republic

**Resumen**—En este trabajo presentamos un algoritmo de comparación de imágenes basado en mediciones de similitud entre vecindarios de píxeles a través de las llamadas funciones de semejanza de matrices (o *matrix resemblance functions*, término original). Además, inspirados por los conceptos de funciones de equivalencia restringida y grados de inclusión de Sinha y Dougherty, estudiamos dos métodos de construcción para funciones de semejanza de matrices, que las dotan de una expresión algebraica y permiten así estudiar las propiedades que hacen a esta familia de funciones apropiada para la comparación de imágenes. Concluimos el trabajo con un ejemplo que ilustra una potencial aplicación de este tipo de funciones para detectar cambios y movimiento en vídeo.

**Index Terms**—Funciones de agregación, funciones de semejanza de matrices, comparación de imágenes.

## I. INTRODUCCIÓN

Existen en la literatura diversas propuestas para medir cómo de diferentes son dos imágenes en términos de similitud. La comparación de imágenes es ampliamente utilizada en distintos ámbitos, como son el reconocimiento facial [1], mejora de escenas [2] y detección de fallos o anomalías en series de producción [3], entre otros.

En consecuencia, es posible encontrar numerosas medidas e índices de similitud en la literatura [4], [5]. Una de las diferencias entre el método que se presenta en este trabajo y muchos otros es que se trata de un método basado en la comparación de vecindarios, en lugar de llevar a cabo una comparación píxel a píxel. Otra diferencia notable es que la mayoría de técnicas de comparación son medidas numéricas, i.e., el resultado se reduce a un número, mientras que nuestra propuesta tiene una nueva imagen como resultado. Además de que un número puede no resultar del todo representativo en cuanto a la similitud de dos imágenes, el beneficio de considerar una nueva imagen como resultado es que hace posible extraer información sobre la localización, es decir, se pueden determinar zonas donde las dos imágenes son más similares o menos y medir cómo de similares son en cada una de esas regiones.

En este trabajo discutimos la noción de funciones de semejanza de matrices, que fueron introducidas con una definición axiomática en [6]. Además, estudiamos dos métodos de construcción basados en funciones de equivalencia restringida [7] y grados de inclusión [8], [9], respectivamente. También analizamos las restricciones necesarias para que estas funciones de esta clase sean adecuadas para comparar imágenes, en otras palabras, las restricciones para que estas funciones satisfagan propiedades frecuentemente requeridas a medidas de comparación de imágenes.

El objetivo de este trabajo, además de discutir la noción y las propiedades de las funciones de semejanza de matrices, es presentar un algoritmo de comparación de imágenes basado en esta familia de funciones. El algoritmo consiste en comparar el vecindario de un píxel de la primera imagen con el correspondiente vecindario del píxel de la segunda imagen. El resultado de dicha comparación se usa como valor para el píxel en esa posición de la nueva imagen, la imagen resultado.

Tras la presentación del algoritmo, presentamos un ejemplo que ilustra cómo puede usarse el algoritmo en una aplicación de detección de cambios o movimiento en vídeo.

Este trabajo se organiza de la siguiente manera. En la Sección II, comenzamos recordando varios conceptos preliminares. En la Sección III presentamos la clase de funciones de semejanza de matrices para matrices  $m \times n$ . En la Sección IV discutimos dos métodos para construir funciones de este tipo basados en funciones de equivalencia restringida y grados de inclusión. En la Sección V estudiamos las propiedades que este tipo de funciones cumple en relación con el problema de la comparación de imágenes. Concluimos este trabajo con un algoritmo de comparación de imagen (Sección VI) y un ejemplo de cómo aplicarlo en un problema de detección de cambios en vídeo en la Sección VII.

## II. PRELIMINARES

Sean  $m, n \in \mathbb{N}$  y denotamos por  $\mathcal{M}_{m \times n}([0, 1])$  al conjunto de matrices  $m \times n$  cuyos elementos pertenecen al intervalo

unidad.

Llamamos negación difusa a la siguiente generalización de la negación en lógica clásica.

**Definición 1.** Se dice que una función  $c : [0, 1]^2 \rightarrow [0, 1]$  es una negación difusa si es decreciente,  $c(0) = 1$  y  $c(1) = 0$ . Además, se dice que  $c$  es estricta si es continua y estrictamente decreciente. Decimos que una negación estricta  $c$  es fuerte si además es involutiva, es decir,  $c(c(x)) = x$  para todo  $x \in [0, 1]$ .

Una función de equivalencia restringida [7] modela la comparación entre dos números en el intervalo unidad.

**Definición 2.** Sea  $c$  una negación fuerte. Una función  $REF : [0, 1]^2 \rightarrow [0, 1]$  es una función de equivalencia restringida con respecto a  $c$  si

- (REF1)  $REF(x, y) = REF(y, x)$  para todos  $x, y \in [0, 1]$ ;
- (REF2)  $REF(x, y) = 1$  si y solo si  $x = y$ ;
- (REF3)  $REF(x, y) = 0$  si y solo si  $\{x, y\} = \{0, 1\}$ ;
- (REF4)  $REF(x, y) = REF(c(x), c(y))$  para todos  $x, y \in [0, 1]$ ;
- (REF5) Para todos  $x, y, z \in [0, 1]$ , si  $x \leq y \leq z$ , entonces  $REF(x, y) \geq REF(x, z)$  y  $REF(y, z) \geq REF(x, z)$ .

En la Sección IV presentamos un método de construcción de funciones de semejanza de matrices en términos de grados de inclusión difusos. Para ello, aprovechamos el hecho de que si consideramos un conjunto de píxeles como universo, un conjunto difuso puede ser como una matriz en  $\mathcal{M}_{m \times n}([0, 1])$ . Denotamos el conjunto formado por todos los conjuntos difusos con universo  $X$  como  $FS(X)$ .

Un grado de inclusión difuso [9], [10], [11] indica cómo de contenido está un conjunto difuso en otro. Existen varias definiciones de esta noción, con diferentes axiomatizaciones [12], [8], [13]. En este trabajo, usamos la introducida por Sinha y Dougherty [8].

**Definición 3.** Se dice que una función  $\sigma : FS(X) \times FS(X) \rightarrow [0, 1]$  es un grado de inclusión en el sentido de Sinha y Dougherty si satisface las siguientes propiedades

- (IG1)  $\sigma(\mathcal{A}, \mathcal{B}) = 1$  si y solo si  $\mathcal{A} \leq \mathcal{B}$ , donde  $\mathcal{A} \leq \mathcal{B}$  significa que  $\mathcal{A}(x) \leq \mathcal{B}(x)$  para todo  $x \in X$ ;
- (IG2)  $\sigma(\mathcal{A}, \mathcal{B}) = 0$  si y solo si existe  $x_i$  tal que  $\mathcal{A}(x_i) = 1$  y  $\mathcal{B}(x_i) = 0$ ;
- (IG3) Si  $\mathcal{B} \leq \mathcal{C}$ , entonces  $\sigma(\mathcal{A}, \mathcal{B}) \leq \sigma(\mathcal{A}, \mathcal{C})$  para todo  $\mathcal{A} \in FS(X)$ ;
- (IG4) Si  $\mathcal{B} \leq \mathcal{C}$ , entonces  $\sigma(\mathcal{C}, \mathcal{A}) \leq \sigma(\mathcal{B}, \mathcal{A})$  para todo  $\mathcal{A} \in FS(X)$ ;
- (IG5)  $\sigma(\mathcal{A}, \mathcal{B}) = \sigma(\pi(\mathcal{A}), \pi(\mathcal{B}))$ , siendo  $\pi$  una permutación de los elementos de  $X$  y con  $\pi(\mathcal{A})(x) = \mathcal{A}(\pi(x))$  y  $\pi(\mathcal{B})(x) = \mathcal{B}(\pi(x))$ ;
- (IG6)  $\sigma(\mathcal{A}, \mathcal{B}) = \sigma(\mathcal{B}_c, \mathcal{A}_c)$ , siendo  $c$  una negación fuerte;
- (IG7)  $\sigma(\mathcal{B} \vee \mathcal{C}, \mathcal{A}) = \min(\sigma(\mathcal{B}, \mathcal{A}), \sigma(\mathcal{C}, \mathcal{A}))$  para todos  $\mathcal{A}, \mathcal{B}, \mathcal{C} \in FS(X)$ ;
- (IG8)  $\sigma(\mathcal{A}, \mathcal{B} \wedge \mathcal{C}) = \min(\sigma(\mathcal{A}, \mathcal{B}), \sigma(\mathcal{A}, \mathcal{C}))$  para todos  $\mathcal{A}, \mathcal{B}, \mathcal{C} \in FS(X)$ ;

$$(IG9) \sigma(\mathcal{A}, \mathcal{B} \vee \mathcal{C}) \geq \max(\sigma(\mathcal{A}, \mathcal{B}), \sigma(\mathcal{A}, \mathcal{C})) \text{ para todos } \mathcal{A}, \mathcal{B}, \mathcal{C} \in FS(X).$$

### III. LA CLASE DE FUNCIONES DE SEMEJANZA DE MATRICES

Recordemos la definición axiomática del concepto de función de semejanza de matrices, introducida en [6] para matrices cuadradas.

**Definición 4** ([6]). Sean  $m, n \in \mathbb{N}$ . Decimos que una función  $\Psi : \mathcal{M}_{m \times n}([0, 1]) \times \mathcal{M}_{m \times n}([0, 1]) \rightarrow [0, 1]$  es una función de semejanza de matrices si cumple las siguientes propiedades:

- (MRF1)  $\Psi(A, B) = 1$  si y solo si  $A = B$ ;
- (MRF2)  $\Psi(A, B) = 0$  si y solo si  $\{a_{ij}, b_{ij}\} = \{0, 1\}$  para algunos  $1 \leq i \leq m$  y  $1 \leq j \leq n$ ;
- (MRF3)  $\Psi(A, B) = \Psi(B, A)$  para todas  $A, B \in \mathcal{M}_{m \times n}([0, 1])$ .

**Ejemplo 1.** La función

$$\Psi(A, B) = \prod_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} (1 - (a_{ij} - b_{ij})^2)$$

es una función de semejanza de matrices.

La condición (MRF2) hace que las funciones de semejanza de matrices estén relacionadas con el operador de erosión de la morfología matemática [6].

El siguiente resultado da una manera de generar nuevas funciones de semejanza de matrices a partir de una dada.

**Proposición 1.** Sean  $\phi, \eta : [0, 1] \rightarrow [0, 1]$  tales que  $\phi(0) = \eta(0) = 0$ ,  $\phi(1) = \eta(1) = 1$ ,  $\eta(x) \in (0, 1)$  para todo  $x \in (0, 1)$ , y sea  $\phi$  inyectiva. Si  $\Psi : \mathcal{M}_{m \times n}([0, 1])^2 \rightarrow [0, 1]$  es una función de semejanza de matrices, entonces  $\Psi_{\phi, \eta} : \mathcal{M}_{m \times n}([0, 1])^2 \rightarrow [0, 1]$  dada por

$$\Psi_{\phi, \eta}(A, B) = \eta(\Psi(\phi(A), \phi(B))), \quad (1)$$

donde  $\phi(A)_{ij} = \phi(a_{ij})$ , también es una función de semejanza de matrices.

La demostración de la proposición anterior se basa en comprobar que la expresión (1) cumple las condiciones (MRF1)-(MRF3).

**Corolario 1.** Sea  $\phi : [0, 1] \rightarrow [0, 1]$  una función estrictamente creciente tal que  $\phi(0) = 0$  y  $\phi(1) = 1$ , y sea  $\Psi$  una función de semejanza de matrices. Entonces, la función  $\Psi_{\phi, \phi^{-1}}$  es de semejanza de matrices.

**Ejemplo 2.** Del Ejemplo 1 y el Corolario 1 se deduce que

$$\Psi(A, B) = \left( \prod_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} (1 - (a_{ij}^2 - b_{ij}^2)^2) \right)^{\frac{1}{2}}$$

es una función de semejanza de matrices.

Por otro lado, es posible también obtener una función de esta clase mediante una agregación de funciones de semejanza



de matrices (más información sobre funciones de agregación en [14]).

**Proposición 2.** Sea  $k \geq 2$  y sea  $F : [0, 1]^k \rightarrow [0, 1]$  sin divisores de cero ni de uno [14]. Si  $\Psi_1, \dots, \Psi_k$  son funciones de semejanza de matrices, entonces la función  $\Psi = F(\Psi_1, \dots, \Psi_k) : \mathcal{M}_{m \times n}([0, 1])^k \rightarrow [0, 1]$  dada por

$$\begin{aligned} \Psi(A, B) &= F(\Psi_1, \dots, \Psi_k)(A, B) \\ &= F(\Psi_1(A, B), \dots, \Psi_k(A, B)), \end{aligned}$$

es una función de semejanza de matrices.

En particular, el resultado de calcular la media aritmética de dos funciones de semejanza de matrices es una nueva función de semejanza de matrices.

#### IV. MÉTODOS DE CONSTRUCCIÓN DE FUNCIONES DE SEMEJANZA DE MATRICES

Para poder exponer los dos métodos de construcción, fijamos una serie de propiedades que una función  $F$  puede cumplir. Sean  $F : [0, 1]^N \rightarrow [0, 1]$ ,  $\mathbf{x} \in [0, 1]^N$  y  $\pi$  una permutación de  $N$  elementos. Denotamos  $\mathbf{x}_\pi = (x_{\pi(1)}, \dots, x_{\pi(N)})$ . Así, podemos fijar las siguientes propiedades.

- (F1)  $F(\mathbf{x}) = 1$  si y solo si  $\mathbf{x} = (1, \dots, 1)$ ,
- (F2)  $F(\mathbf{x}) = 0$  si y solo si  $x_j = 0$  para algún  $1 \leq j \leq N$ ,
- (F3)  $F(\mathbf{x}) = F(\mathbf{x}_\pi)$  para toda permutación  $\pi$  de  $\{1, \dots, N\}$ .

Las primeras dos propiedades fueron estudiadas en [15] para funciones de agregación. Este tipo de funciones han sido ampliamente utilizadas en muchos campos, en particular en visión artificial [16], [17].

El siguiente resultado refleja el primer método de construcción, que está basado en el concepto de función de equivalencia restringida.

**Teorema 1.** Sea  $\beta$  una función que satisfaga (REF1)-(REF3) y  $H : [0, 1]^{mn} \rightarrow [0, 1]$  una función que satisfaga (F1) y (F2). Entonces, la función  $\Psi : \mathcal{M}_{m \times n}([0, 1])^2 \rightarrow [0, 1]$  dada por

$$\Psi(A, B) = H_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}(\beta(a_{ij}, b_{ij})) \quad (2)$$

es una función de semejanza de matrices.

*Demostración.* Sea  $\Psi$  como en (2). Veamos que  $\Psi$  es una función de semejanza de matrices. Para (MRF1), como  $H$  satisface ((F1)), se tiene que

$$H_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}(\beta(a_{ij}, b_{ij})) = 1 \text{ si y solo si } \beta(a_{ij}, b_{ij}) = 1$$

para todos  $1 \leq i \leq m$  y  $1 \leq j \leq n$ . Ahora, por (REF2), esto equivale a que  $a_{ij} = b_{ij}$  para todos  $1 \leq i \leq m$  y  $1 \leq j \leq n$ .

Probemos (MRF2). Por (F2), tenemos que

$$H_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}(\beta(a_{ij}, b_{ij})) = 0 \text{ si y solo si } \beta(a_{ij}, b_{ij}) = 0,$$

para algunos  $1 \leq i \leq m$  y  $1 \leq j \leq n$ ; que, por (REF3), equivale a  $\{a_{ij}, b_{ij}\} = \{0, 1\}$  para algunos  $1 \leq i \leq m$  y  $1 \leq j \leq n$ .

La propiedad (MRF3) también se cumple, ya que, por (REF1),  $\beta(a_{ij}, b_{ij}) = \beta(b_{ij}, a_{ij})$ . □

Llamamos a las funciones de semejanza de matrices construidas de esta forma como generadas por el par  $(H, \beta)$ .

La función de semejanza de matrices del Ejemplo 1 está generada por el par  $(H, \beta)$ , donde  $H$  es el producto y  $\beta(x, y) = 1 - (x - y)^2$ .

El segundo método de construcción está basado en los grados de inclusión en el sentido de Sinha y Dougherty.

**Teorema 2.** Sea  $\sigma : \mathcal{M}_{m \times n}([0, 1])^2 \rightarrow [0, 1]$  que satisfaga (IG1) y (IG2) y sea  $M : [0, 1]^2 \rightarrow [0, 1]$  una función satisfaciendo (F1)-(F3). Entonces la función  $\Psi : \mathcal{M}_{m \times n}([0, 1])^2 \rightarrow [0, 1]$  dada por

$$\Psi(A, B) = M(\sigma(A, B), \sigma(B, A)), \quad (3)$$

es una función de semejanza de matrices.

*Demostración.* Sea  $\Psi$  como en (3). Primero, para (MRF1), como  $M$  satisface ((F1)), se tiene que  $M(\sigma(A, B), \sigma(B, A)) = 1$  si y solo si  $\sigma(A, B) = \sigma(B, A) = 1$ . Por (IG1), esto equivale a  $A \leq B$  y  $B \leq A$ , que, a su vez, equivale a  $A = B$ .

(MRF2) se sigue de que  $\Psi(A, B) = M(\sigma(A, B), \sigma(B, A)) = 0$  si y solo si  $\sigma(A, B) = 0$  or  $\sigma(B, A) = 0$ , por ((F2)). Y, esto equivale a  $(a_{ij} = 1$  y  $b_{ij} = 0)$  o  $(a_{ij} = 0$  y  $b_{ij} = 1)$ .

(MRF3) es directo por ((F3)). □

Llamamos a las funciones de semejanza de matrices construidas por este método como las generadas por el par  $(M, \sigma)$ .

**Ejemplo 3.** La función dada por

$$\Psi(A, B) = \min \left( \inf_{i,j} \{I_L(a_{ij}, b_{ij})\}, \inf_{i,j} \{I_L(b_{ij}, a_{ij})\} \right),$$

donde  $I_L$  denota la implicación de Lukasiewicz,  $I_L(x, y) = \min(1, 1 - x + y)$ , es una función de semejanza de matrices construida por el segundo método, generada por  $\sigma(A, B) = \inf_{i,j} \{I_L(a_{ij}, b_{ij})\}$  y  $M$  el mínimo.

#### V. PROPIEDADES DE LAS FUNCIONES DE SEMEJANZA DE MATRICES PARA LA COMPARACIÓN DE IMÁGENES

Existen una serie de propiedades que son estándares en medidas para comparar imágenes [4], [5]. En esta sección presentamos las condiciones bajo las cuales las funciones sobre las que versa este trabajo cumplen varias de esas propiedades.

##### V-A. Igualdad y simetría

Es frecuente que una medida de comparación de imágenes solo pueda dar el máximo resultado posible cuando las dos imágenes a comparar sean la misma. Las funciones de semejanza de matrices cumplen esta condición por el primer axioma.

Otra propiedad habitual es que el orden en que se comparen ambas imágenes no tenga ningún efecto en el resultado. La condición (MRF3) asegura esta propiedad.

### V-B. Complementos binarios y en grises

Según [4], una medida de similitud debe dar 0 cuando comparamos una imagen en blanco y negro con su negativa. Las funciones de semejanza de matrices cumplen esta propiedad debido al segundo axioma.

Otra propiedad deseada para esta clase de medidas es que el resultado de comparar dos imágenes cualesquiera y de comparar sus complementos por una negación fuerte sea el mismo. Es decir, se busca que  $\Psi(A, B) = \Psi(A_c, B_c)$ , con  $c$  una negación fuerte y  $A_c = (c(a_{ij}))_{i,j=1}^n$  y  $B_c = (c(b_{ij}))_{i,j=1}^n$ .

En este respecto, tenemos los siguientes dos resultados.

**Proposición 3.** *Sea  $\Psi$  una función de semejanza de matrices generada por el par  $(H, \beta)$  tal que  $\beta$  cumple (REF4). Entonces  $\Psi$  satisface  $\Psi(A, B) = \Psi(A_c, B_c)$ .*

**Proposición 4.** *Sea  $\Psi$  una función de semejanza de matrices generada por el par  $(M, \sigma)$  tal que  $\sigma$  cumple (IG6). Entonces  $\Psi$  satisface  $\Psi(A, B) = \Psi(A_c, B_c)$ .*

Los recíprocos de estos resultados no se cumplen en general.

### V-C. Invariancia por permutaciones

También es natural que la comparación de dos imágenes y la comparación de las mismas tras una transformación del dominio (ya sea una refracción, una rotación, etc.) obtengan el mismo resultado.

Consecuentemente, estudiamos las condiciones que tiene que cumplir una función de semejanza de matrices  $\Psi$  para que se cumpla  $\Psi(A, B) = \Psi(\pi(A), \pi(B))$ , para todas  $A, B \in \mathcal{M}_{m \times n}([0, 1])$  y toda permutación  $\pi$  del conjunto de índices.

**Teorema 3.** *Sea  $\Psi$  una función de semejanza de matrices generada por el par  $(H, \beta)$ . Entonces  $\Psi$  cumple  $\Psi(A, B) = \Psi(\pi(A), \pi(B))$ , para todas  $A, B$  y permutación  $\pi$  si y solo si  $H$  satisface (F3).*

**Proposición 5.** *Sea  $\Psi$  una función de semejanza de matrices generada por el par  $(M, \sigma)$ . Si  $\sigma$  cumple (IG5), entonces  $\Psi$  cumple  $\Psi(A, B) = \Psi(\pi(A), \pi(B))$ , para todas  $A, B$  y permutación  $\pi$ .*

### V-D. Monotonía

Llamamos monotonía a la siguiente condición, que asegura que el resultado de la comparación crece o decrece acorde a la diferencia en luminosidad.

(M) Si  $A \leq B \leq C$ , entonces  $\Psi(A, C) \leq \Psi(A, B)$  y  $\Psi(A, C) \leq \Psi(B, C)$ .

Los siguientes resultados dan las condiciones bajo las cuales una matriz de semejanza de matrices cumple la condición (M).

**Teorema 4.** *Sea  $\Psi$  una función de semejanza de matrices generada por el par  $(H, \beta)$  con  $H$  una función creciente. Si  $\beta$  cumple (REF5), entonces  $\Psi$  cumple (M). Además, si  $H$  es estrictamente creciente en  $(0, 1]^{mn}$ , el recíproco también se cumple.*

En particular, una función de semejanza de matrices  $\Psi$ , generada por el par  $(H, \beta)$  con  $\beta$  una función de equivalencia restringida y  $H$  una función de agregación que cumpla (F1)-(F2), satisface la propiedad (M).

**Teorema 5.** *Sea  $\Psi$  una función de semejanza de matrices generada por el par  $(M, \sigma)$  con  $M$  una función creciente. Si  $\sigma$  cumple (IG3) y (IG4), entonces  $\Psi$  cumple (M).*

### V-E. Invariancia por cambios constantes de luminosidad

Es deseable que el resultado de comparar dos imágenes y las mismas con un cambio constante en la luminosidad coincida. Es decir, buscamos que

$$\Psi(A + \lambda, B + \lambda) = \Psi(A, B), \quad (4)$$

donde  $\lambda$  es la matriz  $m \times n$  formada por  $\lambda \in [0, 1 - \max(a_{ij}, b_{ij})]$  en todas las posiciones.

Los siguientes son los resultados que indican bajo qué condiciones una función de semejanza de matrices, construida mediante una de las dos construcciones presentadas, cumple la condición (4).

**Proposición 6.** *Sean  $A, B \in \mathcal{M}_{m \times n}([0, 1])$ ,  $\lambda \in [0, 1 - \max(a_{ij}, b_{ij})]$  y sea  $\Psi$  una función de semejanza de matrices generada por el par  $(H, \beta)$  con  $\beta$  tal que  $\beta(x + \lambda, y + \lambda) = \beta(x, y)$ . Entonces  $\Psi$  cumple (4).*

**Proposición 7.** *Sean  $A, B \in \mathcal{M}_{m \times n}([0, 1])$ ,  $\lambda \in [0, 1 - \max(a_{ij}, b_{ij})]$  y sea  $\Psi$  una función de semejanza de matrices generada por el par  $(M, \sigma)$  con  $\sigma$  tal que  $\sigma(A + \lambda, B + \lambda) = \sigma(A, B)$ . Entonces  $\Psi$  cumple (4).*

## VI. ALGORITMO DE COMPARACIÓN DE IMÁGENES

En esta sección presentamos un algoritmo para comparar imágenes en escala de grises que se basa en medir la similitud entre los vecindarios correspondientes a píxeles de las dos imágenes (matrices  $m \times n$ ).

Una de las ventajas de este método es que, mientras que el resultado de comparar dos vecindarios con una función de semejanza de matrices es un número, el resultado de comparar dos imágenes es una tercera que permite delimitar las zonas donde las imágenes se parecen más o menos, las zonas donde las dos imágenes son igual de parecidas o igual de distintas. En consecuencia, uno de los últimos pasos de nuestro algoritmo es segmentar la imagen resultante para obtener las diferentes regiones de similitud.

En la siguiente sección ilustramos la forma de utilizar este algoritmo para detectar cambios u objetos en movimiento en vídeo. Para este tipo de aplicación, donde se pretende separar el objeto en movimiento del fondo, utilizamos un algoritmo de umbralización como técnica para segmentar la imagen al final del algoritmo. Las técnicas de umbralización [18] consisten en dar con un umbral en las intensidades de la imagen que separan el objeto del fondo: los píxeles con una intensidad mayor a dicho umbral se clasifican como objeto y los restantes como fondo, o viceversa. La ventaja de utilizar este tipo de técnica para la segmentación es su bajo coste computacional.



El algoritmo que presentamos, Algorithm 1, recibe dos imágenes del mismo tamaño en escala de grises y devuelve una nueva imagen, la imagen de comparación. Una vez obtenemos esta nueva imagen, procedemos a segmentar la imagen con el algoritmo de umbralización de Otsu [19].

---

**Algorithm 1** Algoritmo de comparación de imágenes

---

**Input:** Dos imágenes (del mismo tamaño) a comparar:  $I_1$  y  $I_2$

**Output:** La imagen de comparación  $C$  y el umbral  $t$

- 1: **for** cada píxel en  $I_1$  **do**
  - 2:   Determinar su vecindario en  $I_1$  y el correspondiente en  $I_2$
  - 3:   Usar una función de semejanza de matrices para comparar los vecindarios
  - 4:   Fijar el valor del píxel de  $C$  en esa posición con el resultado dado por la función de semejanza de matrices
  - 5: **end for**
  - 6: Aplicar el algoritmo de Otsu a  $C$  para obtener el umbral  $t$
- 

## VII. DETECCIÓN DE CAMBIOS Y MOVIMIENTO EN VÍDEO

En esta sección mostramos cómo puede ser utilizado el algoritmo de la sección anterior para detectar objetos en movimiento en un vídeo. El método consiste en comparar cada fotograma de un vídeo con un fotograma en el que el objeto a detectar no aparece (o no se mueve). Como ejemplo ilustrativo, en este trabajo utilizamos de fotograma de referencia el primero del vídeo. De esta forma, comparando cada fotograma con el señalado, logramos tantas imágenes de comparación como fotogramas tiene el vídeo. Es decir, obtenemos un nuevo vídeo en el que el objeto en movimiento es separado del fondo.

Nótese que es posible que en algún (incluso en muchos) fotogramas de un vídeo, el objeto a detectar no aparezca y no haya movimiento alguno. En estos casos, el algoritmo de Otsu nos dará un umbral muy cercano a 255 (máximo), que no será significativo. Por esta razón, en este ejemplo modificamos el algoritmo para solo tener en cuenta los umbrales que indican que ha habido un cambio significativo en la imagen. Consideramos que ha habido un cambio significativo cuando el umbral que obtenemos segmenta la imagen en dos zonas que contienen al menos el 20% de las posibles intensidades. Es decir, si el umbral  $t \geq 204$ , consideramos que no ha habido cambios significativos y no segmentamos la imagen. Hay que tener en cuenta que escogemos este parámetro con fines ilustrativos, en una aplicación real requiere ser optimizado.

Utilizamos como ejemplo un fragmento de vídeo de la categoría básica de una base de datos de detección de cambios<sup>1</sup>, que se describe en [20]. Al tratarse de vídeos a color, al extraer los fotogramas los transformamos a escala de grises y la función de semejanza de matrices que utilizamos para este ejemplo es la generada por el par  $(H, \beta)$ , con  $H = \min$  y  $\beta(x, y) = 1 - |x - y|$ .

<sup>1</sup>www.changedetection.net

El vídeo de este ejemplo proviene de una cámara fija en un escenario exterior que graba a viandantes en la calle. En la primera fila de la Figura 1 enseñamos cuatro fotogramas del vídeo original en las que se vislumbran dos personas. La segunda fila muestra los resultados de comparar cada fotograma con el fotograma de referencia (Figura 2), donde no hay ningún viandante. En la tercera fila observamos el resultado de aplicar el algoritmo de Otsu para segmentar la imagen y separar las personas en movimiento del fondo. La cuarta fila muestra la segmentación ideal, etiquetada por humanos, que podemos encontrar en la base de datos.

Recalamos que el objetivo de este trabajo es presentar un algoritmo para comparar imágenes que se basa en el concepto de función de semejanza de matrices. El ejemplo de detección de cambios en vídeo es meramente ilustrativo, de ahí que no evaluemos numéricamente los resultados ni comparemos el método con otros en la literatura.



Figura 2. Primer fotograma del vídeo, fotograma de referencia para llevar a cabo la comparación.

## VIII. CONCLUSIONES

En este trabajo hemos estudiado la clase de funciones de semejanza de matrices (*matrix resemblance functions*). Hemos definido el concepto y hemos discutido varios métodos de construcción, primero estudiando la forma de generar estas funciones partiendo de otras de las mismas características y luego apoyándonos en los conceptos de funciones de equivalencia restringida y de grado de inclusión. Además, hemos mostrado varias propiedades de esta clase de funciones que justifican su uso en un algoritmo de comparación de imagen. En la última parte del trabajo, hemos expuesto dicho algoritmo y hemos ilustrado mediante un ejemplo una posible aplicación para detectar movimiento en vídeo.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el servicio de investigación de la Universidad Pública de Navarra y los proyectos APVV-14-0013 y TIN2016-77356-P (AEI/FEDER, UE).

## REFERENCIAS

- [1] R. Moreton and J. Morley, "Investigation into the use of photoanthropometry in facial image comparison," *Forensic Science International*, vol. 212, no. 1, pp. 231 – 237, 2011.
- [2] M. R. Stevens and J. R. Beveridge, "Image comparison techniques in the context of scene refinement," in *Pattern Recognition, 2000. Proceedings. 15th International Conference on*, vol. 1. IEEE, 2000, pp. 685–688.
- [3] H. Rau and C.-H. Wu, "Automatic optical inspection for detecting defects on printed circuit board inner layers," *The International Journal of Advanced Manufacturing Technology*, vol. 25, no. 9, pp. 940–946, 2005.

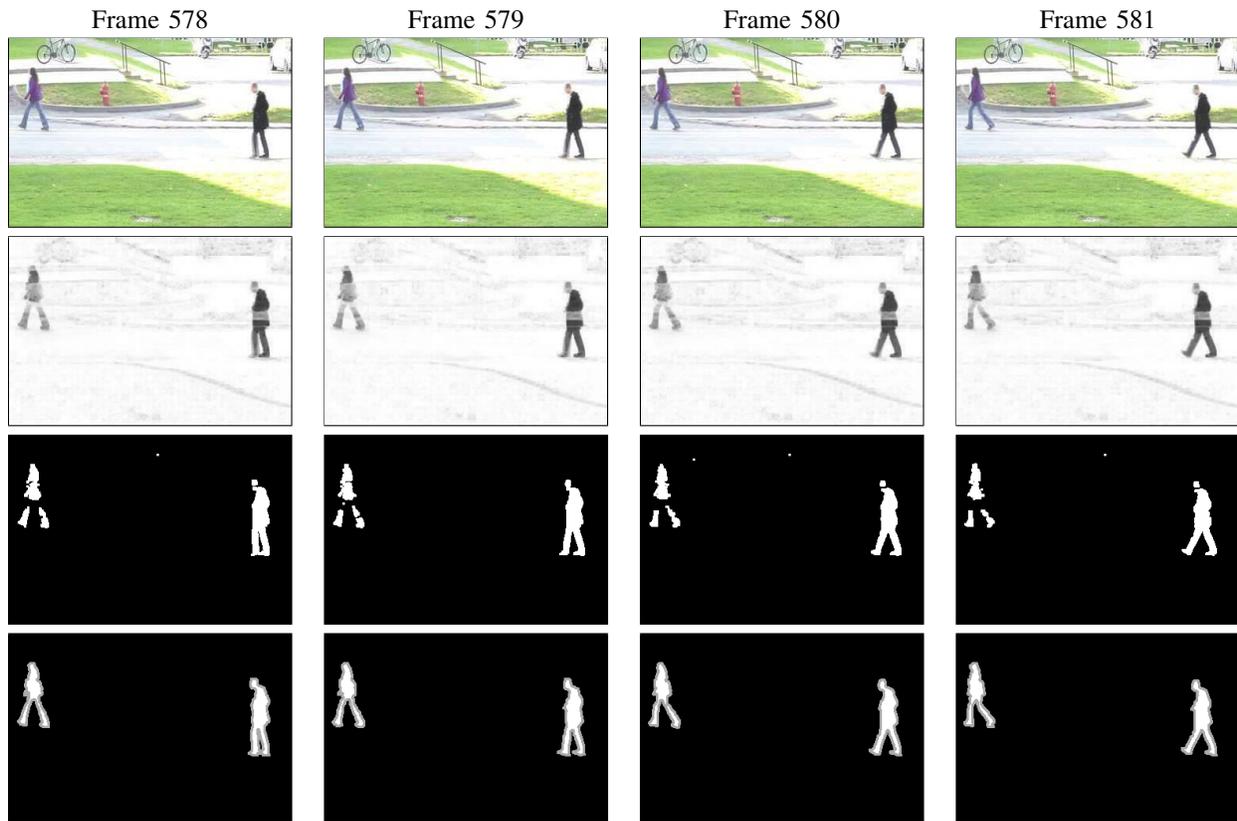


Figura 1. *Primera fila:* Fotogramas originales del vídeo. *Segunda fila:* Resultados de comparar los fotogramas del vídeo con el fotograma de referencia. *Tercera fila:* Resultado de aplicar el algoritmo de umbralización de Otsu. *Cuarta fila:* Imágenes de referencia etiquetadas por humanos.

- [4] H. Bustince, M. Pagola, and E. Barrenechea, "Construction of fuzzy indices from fuzzy DI-subsethood measures: Application to the global comparison of images," *Information Sciences*, vol. 177, no. 3, pp. 906 – 929, 2007.
- [5] D. V. der Weken, M. Nachtegaele, and E. E. Kerre, "Using similarity measures and homogeneity for the comparison of images," *Image and Vision Computing*, vol. 22, no. 9, pp. 695 – 702, 2004.
- [6] M. Sesma-Sara, L. De Miguel, M. Pagola, A. Burusco, R. Mesiar, and H. Bustince, "New measures for comparing matrices and their application to image processing," *Applied Mathematical Modelling*, vol. 61, pp. 498 – 520, 2018.
- [7] H. Bustince, E. Barrenechea, and M. Pagola, "Restricted equivalence functions," *Fuzzy Sets and Systems*, vol. 157, no. 17, pp. 2333 – 2346, 2006.
- [8] D. Sinha and E. R. Dougherty, "Fuzzification of set inclusion: Theory and applications," *Fuzzy Sets and Systems*, vol. 55, no. 1, pp. 15 – 42, 1993.
- [9] H. Bustince, "Indicator of inclusion grade for interval-valued fuzzy sets. Application to approximate reasoning based on interval-valued fuzzy sets," *International Journal of Approximate Reasoning*, vol. 23, no. 3, pp. 137 – 209, 2000.
- [10] H. Bustince, E. Barrenechea, M. Pagola, and F. Soria, "Weak fuzzy S-subsethood measures: Overlap Index," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 14, no. 05, pp. 537–560, 2006.
- [11] H. Bustince, V. Mohedano, E. Barrenechea, and M. Pagola, "Definition and construction of fuzzy DI-subsethood measures," *Information Sciences*, vol. 176, no. 21, pp. 3190 – 3231, 2006.
- [12] L. M. Kitainik, *Fuzzy Inclusions and Fuzzy Dichotomous Decision Procedures*. Dordrecht: Springer Netherlands, 1987, pp. 154 – 170.
- [13] V. R. Young, "Fuzzy subsethood," *Fuzzy Sets and Systems*, vol. 77, no. 3, pp. 371 – 384, 1996.
- [14] G. Beliakov, H. Bustince, and T. Calvo, *A Practical Guide to Averaging Functions*, ser. Studies in Fuzziness and Soft Computing. Springer International Publishing, 2016.
- [15] H. Bustince, J. Montero, E. Barrenechea, and M. Pagola, "Semiautoduality in a restricted family of aggregation operators," *Fuzzy Sets and Systems*, vol. 158, no. 12, pp. 1360 – 1377, 2007.
- [16] G. Beliakov, H. Bustince, and D. Paternain, "Image reduction using means on discrete product lattices," *IEEE Transactions on Image Processing*, vol. 21, no. 3, pp. 1070–1083, 2012.
- [17] D. Paternain, J. Fernández, H. Bustince, R. Mesiar, and G. Beliakov, "Construction of image reduction operators using averaging aggregation functions," *Fuzzy Sets and Systems*, vol. 261, pp. 87–111, 2015.
- [18] A. Jurio, H. Bustince, M. Pagola, A. Pradera, and R. R. Yager, "Some properties of overlap and grouping functions and their application to image thresholding," *Fuzzy Sets and Systems*, vol. 229, pp. 69–90, 2013.
- [19] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE transactions on systems, man, and cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [20] N. Goyette, P.-M. Jodoin, F. Porikli, J. Konrad, and P. Ishwar, "Change-detection. net: A new change detection benchmark dataset," in *Computer Vision and Pattern Recognition Workshops (CVPRW), 2012 IEEE Computer Society Conference on*. IEEE, 2012, pp. 1–8.



# Detección del Fracaso Académico y Evaluación de la Práctica Docente mediante la Comunicación Automatizada con un Chatbot

Jeovani M. Morales, Rosana Montes y Francisco Herrera

Andalusian Research Institute on Data Science and Computational Intelligence, DaSCI

Universidad de Granada, Granada, España

E-mails: jeovani@correo.ugr.es, rosana@ugr.es, herrera@decsai.ugr.es

**Resumen**—Este estudio contempla el uso de un modelo simple de comunicación automatizada a través de un chatbot de Telegram, denominado EDUtrack, que se conecta a Moodle, un Sistema de Gestión del Aprendizaje. Está pensado para docentes interesados en evaluar sus clases de alguna manera, así como mantener informados a sus estudiantes sobre su rendimiento académico. EDUtrack define dos perfiles de usuario, estudiante y docente, que a través del uso de comandos interactúan con el bot para obtener información específica. El estudiante será informado de su Factor de Riesgo Académico si se encuentra en riesgo de suspender la asignatura. Al mismo tiempo permitirá recoger la percepción de los estudiantes sobre la satisfacción de la práctica docente a través del uso de información lingüística. El perfil de docente por su parte, podrá solicitar en cualquier momento el listado de los estudiantes con un Factor de Riesgo Académico crítico, así como revisar el resultado de la evaluación proporcionada por los estudiantes de su práctica docente.

## I. INTRODUCCIÓN

Las Instituciones de Educación Superior (IES), están experimentando una constante evolución dirigida a la mejora de la experiencia de aprendizaje de los estudiantes, así como a proporcionar nuevas metodologías que permitan ofrecer una educación de calidad. El fracaso académico, ya sea por deserción o suspenso de una o varias asignaturas, es un problema recurrente en la educación actual. Según los informes de Eurostat 2016<sup>1</sup> la proporción de personas con abandono escolar en la Unión Europea se encuentra en un 10.7%, mientras que España ocupa el segundo puesto de mayor abandono con un 19%. Actualmente con la integración de las tecnologías de la información (TIC), los Sistemas de Gestión del Aprendizaje (LMS por sus siglas en inglés), surge una gran cantidad de información sobre el estudiante. Esta información puede ser tratada para identificar comportamientos en los estudiantes, así como la detección de aquellos que se encuentren en riesgo de fracaso académico.

Frente a esta situación, un profesor comprometido con la provisión de un ambiente de educación de calidad se cuestiona la razón del fracaso de sus alumnos. ¿Es el profesor quien no cubre las necesidades de los estudiantes o es el mismo estudiante quien es responsable de su fracaso?

En esta comunicación se proponen dos métricas que pueden ayudar a clarificar este interrogante, el cálculo del Factor de Riesgo Académico (*FRA*), y la Evaluación de la Práctica Docente (*EPD*). *FRA* es un indicador que proporciona información sobre el rendimiento académico de un estudiante y determina la situación en la que se encuentra su factor de riesgo: ninguno, bajo, moderado, crítico, muy crítico o irrecuperable. Actualmente existen dos campos de investigación dedicados al análisis de estos datos: Educational Data Mining (EDM) [1] y Learning Analytics (LA) [2], los cuales han sido utilizados en diversos estudios que abordan la predicción o detección temprana de estudiantes en riesgo de fracaso académico [3, 4] y detección y reducción del abandono escolar [5, 6]. En estos ámbitos de trabajo los resultados pueden no ser fáciles de interpretar cuando no se tiene experiencia en minería de datos.

*EPD* es una métrica que se obtiene en base a la satisfacción de los estudiantes con respecto a este criterio. La satisfacción es un sentimiento subjetivo basado en las percepciones de quien evalúa. Las percepciones por su naturaleza suelen ser vagas e imprecisas, colocándonos en un entorno difuso de toma de decisiones. En un entorno como este, el uso de un modelo lingüístico en lugar de la información numérica puede ser más adecuado por la naturaleza de la información al utilizar *Linguistic Decision Making* (LDM) [7].

Cuando un problema se resuelve utilizando información lingüística, requiere de un modelo computacional para procesar la información. Dentro de la teoría difusa se destaca la metodología de Computing with Words (CW) [8]. Esta metodología procesa con palabras en lugar de números proponiendo una forma directa de realizar procesos computacionales lingüísticos.

Con base a lo anterior, la evaluación de la práctica docente se puede abordar como un problema LDM, donde se procesa información lingüística para determinar la mejor opción en un problema de toma de decisiones, que a su vez es evaluada por múltiples expertos convirtiéndose en un problema *Multi-Expert Linguistic Decision Making* (MELDM). Cada estudiante es un experto de la experiencia de aprendizaje lo que les permite ser perfectos evaluadores al ofrecer su percepción de forma lingüística para evaluar la práctica docente.

Este trabajo propone la integración de un bot de Tele-

<sup>1</sup><http://ec.europa.eu/eurostat> - Europe 2020: early leavers from education and training

gram con Moodle, denominado EDUtrack, el cual sirve como medio de comunicación automatizada para informar de forma continua a los estudiantes su *FRA*, y al mismo tiempo al docente sobre aquellos estudiantes que se encuentran en riesgo de fracaso académico. Además, sirve de instrumento para la recogida y procesamiento de los datos utilizando el modelo de representación lingüística de 2-tuplas [9] para operar con valoraciones lingüísticas y así evaluar la práctica docente.

El trabajo se estructura de la siguiente forma. En la Sección 2 se introduce los conceptos significativos del estudio, abordando los LMS, chatbots y los modelos lingüísticos de toma de decisiones. La Sección 3 describe el procedimiento para calcular el Factor de Riesgo Académico y la Evaluación de la Práctica Docente. La Sección 4 presenta la herramienta EDUtrack y sus funcionalidades. En la Sección 5 se describe un ejemplo ilustrativo de los cálculos anteriores. Para finalizar en la Sección 6 con la discusión de las conclusiones.

## II. ANTECEDENTES

En esta sección se detalla los aportes de la integración de los sistemas LMS en la educación. Más adelante se define el concepto de chatbot y su interacción con el usuario. Finalmente se realiza una breve introducción al modelo lingüístico de 2-tuplas para la toma de decisiones.

### A. Sistemas de Gestión del Aprendizaje

La integración de las tecnologías de la información y comunicación (TIC) han abierto las puertas a modalidades como e-learning (totalmente en línea) y b-learning (aprendizaje mezclado). Estas modalidades hacen uso de la tecnología para crear nuevos espacios de aprendizaje en donde los estudiantes pueden acceder a los recursos y actividades de una forma más simple y eficiente gracias a las herramientas tecnológicas.

Una de las principales herramientas implementadas por las IES para mejorar la enseñanza [10] y que ha permitido la sinergia entre la educación y las tecnologías, son los LMS, siendo Moodle el software libre más popular actualmente. Un LMS nos permite realizar un seguimiento en línea de los avances del estudiante al emplearse para la entrega de recursos educativos electrónicos, el apoyo de entornos interactivos y la gestión de evaluaciones [11].

La integración de los LMS, genera una gran cantidad de datos relacionados con el proceso de enseñanza aprendizaje. Estos datos se pueden analizar para predecir con base a la conducta y acciones de los estudiantes dentro de los LMS, el rendimiento académico y el riesgo de fracaso escolar.

### B. Chatbots de Telegram

Telegram es una de las aplicaciones móviles de mensajería instantánea más populares. Entre sus características podemos encontrar que es libre, abierto y provee de privacidad, rapidez, y seguridad. Además, cuenta con el servicio de chatbots. Un chatbot es un sistema informático que utiliza Inteligencia Artificial y el aprendizaje automático, capaz de mantener un diálogo mediante un lenguaje natural con un humano [12].

Los usuarios pueden comunicarse e interactuar con los chatbots mediante una serie de comandos preprogramados gracias a la API de Telegram<sup>2</sup>. A su vez los chatbots se pueden conectar a Moodle con el uso de Web service API functions<sup>3</sup> del sistema. Con ello se puede extraer información analítica del estudiante en el curso (calificaciones de actividades, registros de uso, datos informativos del estudiante, entre otros).

### C. Modelos Lingüísticos de Toma de Decisiones

La toma de decisiones es una actividad inherente a los seres humanos. Dependiendo del problema abordado, muchos de los casos se pueden tratar con información numérica y precisa. Sin embargo, en otro tipo de problemas donde las decisiones se basan en información como opiniones o percepciones, el enfoque difuso [13] y el uso de variables lingüísticas han dado buenos resultados.

Zadeh [13] introdujo el concepto de variable lingüística, como aquella variable cuyos valores no son numéricos, sino palabras en un lenguaje natural. Una variable lingüística es menos precisa que una variable numérica, pero más cercana a los procesos cognitivos humanos.

Existen diversos métodos para abordar los problemas LDM (TOPSIS [14], ELECTRE [15], entre otros). Desde la perspectiva de la lógica difusa, cuando los modelos probabilísticos ya no son tan funcionales y existe una tolerancia a la imprecisión surgen metodologías como *Computing with Words* (CW) [8].

Debido al uso de LDM en el mundo real y la necesidad de CW, existen diversos modelos computacionales lingüísticos, que denominaremos clásicos, como el modelo basado en funciones de membresía [16], modelo simbólico lingüístico [17]. Estos modelos clásicos requieren de un proceso de aproximación para proporcionar resultados lingüísticos interpretables.

### D. Modelo Computacional Lingüístico 2-tuplas

Herrera y Martínez [9] presentaron el modelo de representación lingüística de 2-tuplas, resolviendo algunos problemas de precisión y pérdida de información que presentaban los modelos clásicos. La representación lingüística 2-tuplas define el valor de la traslación simbólica  $\alpha$  como el valor correspondiente a la diferencia de información entre un valor  $i$  de índice con correspondencia directa al término lingüístico que se espera como resultado. Sea  $S = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos utilizado para toma de decisiones. Sea  $\beta \in [0, g]$  el valor resultante de un operador simbólico, donde  $g + 1$  es la cardinalidad de  $S$ . La información lingüística es expresada con el par  $(s_i, \alpha)$ , esto es,  $s_i$  la etiqueta lingüística más cercana en el conjunto  $S$  y  $\alpha$  valor numérico de traslación simbólica. Las operaciones de transformación de esta representación son dos:

- La función  $\Delta : [0, g] \rightarrow \langle S \rangle$ , asigna una 2-tupla asociada a  $S$  y definida como  $\langle S \rangle = S \times [-0.5, 0.5]$ :

$$\Delta(\beta) = (s_i, \alpha), \text{ con } i = \text{round}(\beta), \alpha = \beta - i. \quad (1)$$

<sup>2</sup><https://core.telegram.org/api>

<sup>3</sup>[https://docs.moodle.org/dev/Web\\_service\\_API\\_functions](https://docs.moodle.org/dev/Web_service_API_functions)



- La función  $\Delta^{-1} : \langle S \rangle \rightarrow [0, g]$ , identifica una 2-tupla de  $\langle S \rangle$  con un valor numérico en el intervalo  $[0, g]$ :

$$\Delta^{-1}(s_i, \alpha) = i + \alpha = \beta \quad (2)$$

Una vez representada la información lingüística como un valor continuo, se puede operar con dicha información mediante los operadores de agregación. Para la toma de decisión, la agregación de múltiples valores es esencial. Uno de los operadores más comunes es el operador de la media aritmética extendida para valores lingüísticos de 2 tuplas, el cual se define como:

**Definición 1. [9]** Sea  $X = \{(s_1, \alpha_1), \dots, (s_n, \alpha_n)\}$  un conjunto de valores lingüísticos de 2-tuplas, la media aritmética de 2-tuplas,  $x$ , se calcula como:

$$x(X) = \Delta \left( \frac{1}{N} \sum_{i=1}^N \Delta^{-1}(s_i, \alpha_i) \right) \quad (3)$$

### III. DETECCIÓN DEL FRACASO ACADÉMICO Y EVALUACIÓN DE LA PRÁCTICA DOCENTE

Para prevenir el fracaso académico se deben considerar el compromiso de los estudiantes con el proceso de aprendizaje, así como las estrategias aplicadas por el docente en su práctica para llevar los conocimientos a sus estudiantes.

#### A. Factor de Riesgo Académico

*FRA* es un indicador que determina el riesgo de fracaso académico con base a la relación de la diferencia entre el porcentaje máximo posible de las actividades en un momento dado menos el porcentaje obtenido en cada una de esas actividades, con el potencial de recuperación de un estudiante a partir de ese momento hasta el final del ciclo escolar.

Sea  $t$  la variable tiempo que representa la semana en la que se realiza una solicitud para conocer *FRA*; sea  $Q = 15$  el número de semanas totales de un cuatrimestre, se define el ciclo escolar (*CE*) de una asignatura como el conjunto de actividades ordenadas potencialmente calificables a lo largo del tiempo para un estudiante.

En una asignatura se tienen  $N$  estudiantes,  $E = \{E_1, \dots, E_N\}$  tal que  $n = (1, \dots, N)$ . Así mismo la asignatura maneja un máximo de  $J$  actividades ordenadas y predefinidas a lo largo del curso,  $A = \{A_1, \dots, A_J\}$  tal que  $j = (1, \dots, J)$ , como por ejemplo foros, exámenes, etc.

Para determinar el número de actividades abiertas en una semana determinada, tomando en cuenta que dichas actividades son acumulables, se usa la función  $\tau(t) \in [1, J]$ . Es decir, el número de calificaciones totales que puede tener el estudiante al final del curso es  $\tau(Q) = J$ . Nótese que  $\tau(0) = 0$ .

Para reflejar una evaluación continua, el ciclo escolar se define en función de la variable tiempo como  $CE(t) = \{A_1, A_2, \dots, A_{\tau(t)}\}$  con  $t = (1, \dots, 15)$ . Con  $A_i$  recogemos aspectos como calificaciones por examen o por actividad de Moodle. Según el docente, en el cálculo de la calificación, determinadas actividades pueden ser más importantes que otras, por lo que se define  $W_A$  como el vector de pesos de las actividades,  $W_A = \{W_1, \dots, W_J\}$ .

Cada actividad entregada por el estudiante es calificada por el docente definiendo así la calificación obtenida (*CO*) como  $CO_{A_i}(E_n) \in [0, 10]$ . El vector de pesos ordenado con respecto al conjunto de actividades  $A_i$  es  $W(t) = \{W'_1, \dots, W'_{\tau(t)}\}$ . Así mismo se debe definir el conjunto de actividades  $A_k$  con  $k = (\tau(t) + 1, \dots, \tau(Q))$  como el conjunto de actividades que aún no han sido calificadas y su vector de pesos ordenado como  $W(t)^{-1} = \{W''_{\tau(t)+1}, \dots, W''_{\tau(Q)}\}$

Para determinar el *FRA*( $E_n, t$ ) se deben calcular dos valores también dependientes del tiempo,  $\forall t \leq Q$ .

**Definición 2.** La inversa de la calificación  $IC(E_n, t) \in [0, 1]$ , es la relación entre el porcentaje total de calificación de las actividades abiertas en  $t$  y el porcentaje de calificación obtenido por el estudiante en dichas actividades. Cuanto más cerca de 1, mayor será el riesgo de fracaso académico.

$$IC(E_n, t) = 1 - \left( \frac{\sum_{i=1}^{\tau(t)} \left( \frac{W'_i}{10} CO(A_i) \right)}{\sum_{i=1}^{\tau(t)} W'_i} \right) \quad (4)$$

**Definición 3.** El Factor de Recuperación  $FR(E_n, t) \in [0, 1]$  es la relación del porcentaje de calificación obtenidas al momento de una consulta más el porcentaje de calificación de las actividades aún no abiertas. Siendo así,  $FR(E_n, t)$  el máximo porcentaje de calificación que el estudiante puede obtener si obtuviese una calificación perfecta en todas las actividades que quedan por abrirse.

$$FR(E_n, t) = \sum_{i=1}^{\tau(t)} \left( \frac{W'_i}{10} CO(A_i) \right) + \sum_{k=\tau(t)+1}^{\tau(Q)} (W''_k) \quad (5)$$

Para el cálculo de  $FRA \in [0, 1]$ , el tiempo ( $t$ ) es importante así como el factor de recuperación ( $FR$ ) potencial. Juntos determinan la importancia los criterios,  $IC(E_n, t)$  y  $FR(E_n, t)$ . A mayor tiempo, el peso de  $FR$  se reduce y aumenta el de las actividades realizadas.

**Definición 4.** La función Factor de Riesgo Numérico  $FRN(t)$  sirve para determinar el peso de  $IC(E_n, t)$  y  $FR(E_n, t)$  en relación del tiempo en que se realiza una consulta del *FRA*. El parámetro  $\gamma \in [0, 1]$  determina el grado de combinación de 2 factores dependientes del tiempo,  $\gamma = (\tau(t)/Q)FR(E_n, t)$ .

$$FRN(t) = \gamma \cdot (1 - IC(E_n, t)) + (1 - \gamma)FR(E_n, t) \quad (6)$$

por tanto para cada  $t \leq Q$  se define *FRA* como :

**Definición 5.**  $FRA(E_n, \forall t)$  es la relación entre  $IC(E_n, t)$  y  $FR(E_n, t)$  y toma su valor de acuerdo al valor de  $FRN(t)$  según el siguiente conjunto de términos lingüísticos  $S_{FRA} = \{Ninguno, Bajo, Moderado, Crítico, Muy Crítico, Irrecuperable\}$ .

$$FRA(E_n, \forall t) = \begin{cases} \text{Ninguno} & \text{si } 0.9 < FRN(t) \leq 1 \\ \text{Bajo} & \text{si } 0.8 < FRN(t) \leq 0.9 \\ \text{Moderado} & \text{si } 0.7 < FRN(t) \leq 0.8 \\ \text{Crítico} & \text{si } 0.6 < FRN(t) \leq 0.7 \\ \text{Muy Crítico} & \text{si } 0.5 \leq FRN(t) \leq 0.6 \\ \text{Irrecuperable} & \text{si } FRN(t) < 0.5 \end{cases}$$

## B. Evaluación de la Práctica Docente

La satisfacción es una métrica que permite conocer las percepciones de los estudiantes. En el área de marketing existen cuestionarios de una pregunta que son factibles para evaluar la satisfacción de un cliente con un servicio o producto. Estos cuestionarios permiten determinar a los usuarios promotores, pasivos y detractores según su grado de satisfacción. Utilizando la pregunta:

*¿Qué tan satisfecho estás con la práctica docente de tu profesor en esta asignatura?*

mediante la Eq. (3) se procesan las valoraciones de los estudiantes como entrada en un MELDM utilizando la agregación 2 veces para obtener la satisfacción con la experiencia.

**Definición 6.** Sea  $E = \{E_1, \dots, E_N\}$  un conjunto de estudiantes que valoran su propia satisfacción sobre la práctica docente de su profesor. Y sea  $X_t = \{s_1, \dots, s_N\}$  el conjunto de valores lingüísticos proporcionados por los estudiantes para valorar  $EPD(t) \in ([s_0, s_g], \alpha)$  cada semana.

$$EPD(t) = \Delta \left( \frac{1}{t} \sum_{i=1}^t (x(X_i)) \right) \quad (7)$$

## IV. CHATBOT DE TELEGRAM

EDUtrack es una herramienta simple de información y recolección de datos, que funciona como interfaz de comunicación automatizada entre los usuarios (estudiante y docente).

### A. Funcionalidad

A través de comandos tanto el estudiante como docente podrán comunicarse con el bot. Un comando es una instrucción previamente definida en el bot la cual inicia con el símbolo "/". Un comando puede requerir argumentos o no, en este documento se señala como "+arg" en la descripción del comando, siendo "arg" el argumento requerido.

- `/fra_est`: Muestra el *FRA* del estudiante.
- `/eva_docente`: Muestra la pregunta para la evaluación de *EPD*.
- `/fra_asg+id_asignatura`: Muestra el registro de los estudiantes en riesgo de una asignatura.
- `/res_eva_docente +id_asignatura`: Muestra el resultado de *EPD*.

### B. Comunicación con el Estudiante

**Alerta de *FRA* automatizado:** Esta alerta (Fig. 1), se enviará al estudiante cuando su *FRA* adquiera el valor de riesgo moderado o mayor con la finalidad de que pueda tomar acciones para recuperarse. El mensaje contendrá el valor de *FRA* y el valor del Factor de Recuperación (FR), que es la porcentaje máximo que puede obtener el estudiante. Cada semana se calculará el *FRA* de forma automática y se informará solo a aquellos que se encuentren en riesgo, por lo que no requiere de ningún comando de comunicación.

**Consulta de *FRA* :** Mediante el comando `/fra_est` (Fig. 2), EDUtrack proporcionara al estudiante los valores *FRA* y FR al momento de la consulta.

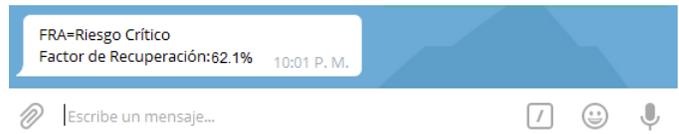


Fig. 1. Mensaje de alerta cuando un estudiante se encuentra en riesgo de fracaso académico.

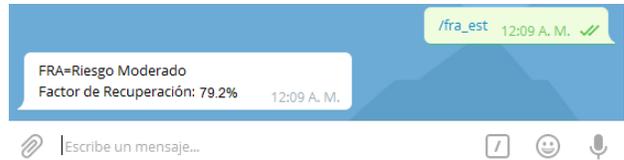


Fig. 2. Solicitud del *FRA* por un estudiante.

***EPD*:** Mediante el comando `/eva_docente` (Fig. 3), el bot proporcionara al estudiante una pregunta y la semántica requerida para valorar su satisfacción con la práctica docente. Dicha evaluación se realiza cada semana con la intención de monitorizar la práctica docente.

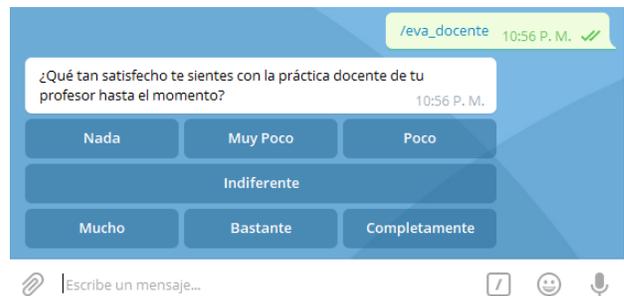


Fig. 3. Evaluación de la práctica docente utilizando información lingüística.

### C. Comunicación con el Docente

**Consulta de *FRA*( $E_n, t$ ):** Mediante el comando `/fra_asg +id_asignatura`, (Fig. 4), se le proporcionara al docente el registro de los estudiantes que se encuentra en riesgo en la asignatura seleccionada al momento de la consulta.



Fig. 4. Resultado de los alumnos en riesgo académico en la asignatura FS1718.

**Consulta de *EPD*:** Mediante el comando `/res_eva_docente +id_asignatura` (Fig. 5), el bot



proporcionara al docente la representación lingüística del resultado de la valoración de los estudiantes sobre la satisfacción de la práctica docente.

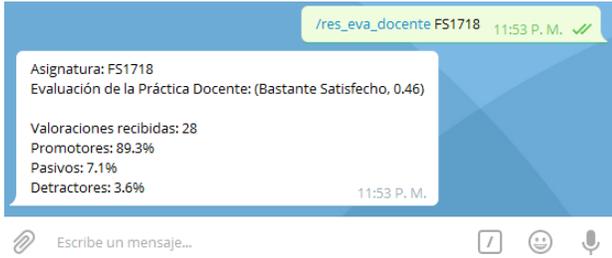


Fig. 5. Resultado de la evaluación de la práctica docente en una asignatura.

### V. EJEMPLO ILUSTRATIVO

Se tomarán 7 estudiantes al azar de una asignatura, para obtener el cálculo del riesgo de fracaso académico y la recolección y procesamiento de información lingüística para la evaluación de la práctica docente en dos semanas distintas de un ciclo escolar, semana 8 y 14. Por cuestiones de espacio, se podrá acceder a los datos utilizados para el ejemplo desde el sitio [https://creasick.github.io/Chatbot\\_FRA/](https://creasick.github.io/Chatbot_FRA/).

#### A. Cálculo del Factor de Riesgo Académico

Para el cálculo del *FRA* de cada estudiante para  $t = 8$  se recoge la información utilizando la Eq. (4), obteniendo los resultados mostrados en la Tabla I:

Tabla I

CÁLCULO DEL FACTOR DE RIESGO ACADÉMICO DE 7 ESTUDIANTES EN LA SEMANA 8 DEL CICLO ESCOLAR.

t=8	E <sub>1</sub>	E <sub>2</sub>	E <sub>3</sub>	E <sub>4</sub>	E <sub>5</sub>	E <sub>6</sub>	E <sub>7</sub>
IC	0.0628	0.1799	0.7285	0.458	0.4281	0.1311	0.4221
FR	0.9706	0.9158	0.6588	0.7855	0.7995	0.9386	0.7883
FRN	0.9696	0.869	0.5277	0.6835	0.7024	0.9037	0.6872
FRA	Ninguno	Bajo	Muy_Crítico	Crítico	Moderado	Ninguno	Crítico

Tabla II

CÁLCULO DEL FACTOR DE RIESGO ACADÉMICO DE 7 ESTUDIANTES EN LA SEMANA 14 DEL CICLO ESCOLAR.

t=14	E <sub>1</sub>	E <sub>2</sub>	E <sub>3</sub>	E <sub>4</sub>	E <sub>5</sub>	E <sub>6</sub>	E <sub>7</sub>
IC	0.1507	0.2242	0.6705	0.5823	0.3309	0.0744	0.5159
FR	0.8674	0.8027	0.41	0.4876	0.7089	0.9345	0.546
FRN	0.8527	0.7825	0.3792	0.4558	0.6826	0.9267	0.5144
FRA	Bajo	Moderado	Irrecuperable	Irrecuperable	Crítico	Ninguno	Muy Crítico

Analizando los resultados de la Tabla I se puede apreciar que en la semana 8, los estudiantes  $E_3$ ,  $E_4$  y  $E_7$ , son los estudiantes con mayor riesgo al fracaso. Aun cuando su *FR* indica que tienen opción de aprobar, claramente el estudiante  $E_3$  se encuentra en una situación complicada, el  $FR_{E_3}$  indica que puede alcanzar hasta 65.88% del porcentaje de la calificación total en caso dado de que el resto de sus actividades fueran perfectas. Mientras que  $FRN_{E_3}$  indica que en base a su desempeño actual durante el ciclo es probable que solo pueda obtener el 52.77%, por lo que se considera que el estudiante se encuentra en riesgo *muy crítico*.

En la Tabla II se observa la semana 14, aquellos estudiantes con un buen rendimiento no modificaron mucho su conducta, mientras que los estudiantes  $E_3$  y  $E_4$ , pasaron de un riesgo considerable, a un riesgo irrecuperable a solo una semana de finalizar el ciclo escolar.

Tomando como ejemplo al estudiante  $E_3$ , quien a pesar de ser informado a medio ciclo escolar (semana 8), se enfrenta a una empresa complicada para recuperarse. EDUtrack tiene una de sus funcionalidades en este punto al informar el FRA desde el inicio del ciclo escolar y de forma continua. Permite tomar diversas estrategias de prevención y recuperación tanto por parte del estudiante como por parte del docente, previniendo así el fracaso académico.

#### B. Evaluación de la Práctica Docente

Como se mencionó previamente en la Sección IV-B, los estudiantes pueden evaluar la práctica docente mediante EDUtrack, (Fig. 3). Cada estudiante por semana proporciona su percepción indicando así su satisfacción. Tras la recolección del vector de preferencias de los estudiantes por semana se puede calcular el  $EPD(t)$  con las valoraciones lingüísticas de los estudiantes.

Tabla III

VALORACIONES SOBRE LA SATISFACCIÓN DE LOS ESTUDIANTES HASTA LA SEMANA 8 DEL CICLO ESCOLAR.

t=8	E <sub>1</sub>	E <sub>2</sub>	E <sub>3</sub>	E <sub>4</sub>	E <sub>5</sub>	E <sub>6</sub>	E <sub>7</sub>	EPD(t)
t <sub>1</sub>	s <sub>5</sub>	s <sub>6</sub>	-	s <sub>5</sub>	s <sub>6</sub>	s <sub>6</sub>	s <sub>4</sub>	(s <sub>5</sub> , 0.33)
t <sub>2</sub>	s <sub>6</sub>	s <sub>6</sub>	-	s <sub>6</sub>	s <sub>6</sub>	s <sub>5</sub>	s <sub>2</sub>	(s <sub>5</sub> , 0.17)
t <sub>3</sub>	s <sub>6</sub>	s <sub>5</sub>	-	s <sub>6</sub>	s <sub>6</sub>	s <sub>5</sub>	s <sub>6</sub>	(s <sub>6</sub> , -0.33)
t <sub>4</sub>	s <sub>6</sub>	s <sub>6</sub>	s <sub>5</sub>	s <sub>6</sub>	s <sub>6</sub>	s <sub>6</sub>	s <sub>6</sub>	(s <sub>6</sub> , -0.14)
t <sub>5</sub>	s <sub>5</sub>	s <sub>6</sub>	s <sub>2</sub>	s <sub>6</sub>	s <sub>5</sub>	s <sub>6</sub>	s <sub>6</sub>	(s <sub>5</sub> , 0.14)
t <sub>6</sub>	s <sub>4</sub>	s <sub>6</sub>	(s <sub>6</sub> , -0.29)					
t <sub>7</sub>	s <sub>6</sub>	s <sub>5</sub>	s <sub>6</sub>	s <sub>6</sub>	s <sub>5</sub>	s <sub>5</sub>	s <sub>6</sub>	(s <sub>6</sub> , -0.43)
t <sub>8</sub>	s <sub>6</sub>	s <sub>6</sub>	s <sub>4</sub>	s <sub>6</sub>	s <sub>4</sub>	s <sub>6</sub>	s <sub>6</sub>	(s <sub>5</sub> , 0.43)
								EPD(t)
								(s <sub>5</sub> , 0.49)
								(Bastante, 0.49)

El cálculo de  $EPD(t)$  es la media aritmética extendida del modelo de 2-tuplas, de la media aritmética extendida de cada una de las semanas transcurridas. En la Tabla III se muestran las valoraciones de los estudiantes sobre su satisfacción en las primeras 8 semanas. El indicador *EDP* nos ofrece información sobre la satisfacción de los estudiantes sobre la práctica docente, siendo el resultado que los estudiantes se sienten *Bastante* satisfechos con la práctica docente. Se puede considerar que el docente puede seguir utilizando las estrategias docentes que ha empleado hasta el momento. Cabe destacar que  $E_3$  no cuenta con valoraciones durante las primeras 3 semanas, y junto con su desempeño académico durante este período, se podría suponer que el estudiante no asistió a clases.

### VI. CONCLUSIÓN

La práctica docente es un factor importante en el proceso de enseñanza aprendizaje, ya que determina el cómo, cuándo y dónde el docente transmite sus conocimientos a los estudiantes, por lo que es importante que sea evaluado desde la perspectiva de estos.

Los dispositivos móviles, así como las aplicaciones de mensajería instantánea son herramientas de uso común entre los estudiantes actuales por lo que son un canal de comunicación que no requiere de un alto coste para implementarse. De esta forma el uso de chatbots actualmente se ha ido incrementado en el ámbito educativo.

Este estudio propone un modelo simple de comunicación automatizada denominada EDUtrack, el cual permitirá informar a los estudiantes de su *FRA*, además de evaluar su satisfacción con la práctica docente. Entre sus bondades podemos encontrar:

- Una interacción sencilla y natural con los estudiantes.
- Es una herramienta de bajo coste y que a pesar de su sencillez tiene un gran potencial, al ofrecer resultados en un lenguaje natural y de fácil comprensión para una persona, mejorando así la interpretación de los resultados.
- Permite el acceso a Moodle y a la información de estudiantes, ofreciendo diversas posibilidades de análisis y toma de decisiones.
- Integra un sistema de información continua sobre el *FRA*, para la detección de estudiantes en riesgo de fracaso académico por lo que está pensado para cualquier docente que pretenda mantenerse al tanto del estatus de sus estudiantes e informarlos sobre su rendimiento académico.
- Permite conocer la satisfacción de los estudiantes con respecto a la práctica docente, con lo que el profesor puede mejorar su desempeño al igual que el estudiante.

Gracias a estas características se pueden desarrollar estrategias preventivas que permitan reducir el fracaso académico y mejorar la calidad educativa.

Las proyecciones a futuro de esta herramienta son:

- 1) Posibilidad de integrar un sistema que genere gráficos para el análisis de la información del *FRA*, lo que proporcionaría un resultado visual que abonaría interpretabilidad al lenguaje natural ya utilizado.
- 2) Actualmente Moodle en su versión 3.4 ha implementado un sistema de detección de estudiantes en riesgo haciendo uso de machine learning. Por lo que se considera que merece la pena realizar una comparación entre el sistema EDUtrack y el sistema que integra Moodle. Así mismo se podría pensar en una integración de ambos sistemas para aprovechar el potencial de cada herramienta.

#### AGRADECIMIENTOS

Este trabajo fue parcialmente apoyado por el proyecto de investigación TIN2017-89517-P del Ministerio de Economía.

#### REFERENCIAS

- [1] C. Romero and S. Ventura, "Educational data mining: A survey from 1995 to 2005," *Expert systems with applications*, vol. 33, no. 1, pp. 135–146, 2007.
- [2] C. Bach, "Learning analytics: Targeting instruction, curricula and student support," *Office of the Provost, Drexel University*, 2010.
- [3] J.-P. Vandamme, N. Meskens, and J.-F. Superby, "Predicting academic performance by data mining methods," *Education Economics*, vol. 15, no. 4, pp. 405–419, 2007.
- [4] L. P. Macfadyen and S. Dawson, "Mining lms data to develop an "early warning system" for educators: A proof of concept," *Computers & education*, vol. 54, no. 2, pp. 588–599, 2010.
- [5] M. Cocea and S. Weibelzahl, "Can log files analysis estimate learners' level of motivation?" in *LWA*. University of Hildesheim, Institute of Computer Science, 2006.
- [6] I. Lykourantzou, I. Giannoukos, V. Nikolopoulos, G. Mpardis, and V. Loumos, "Dropout prediction in e-learning courses through the combination of machine learning techniques," *Computers & Education*, vol. 53, no. 3, pp. 950–965, 2009.
- [7] L. Martínez, R. Rodríguez, and F. Herrera, *The 2-tuple Linguistic Model: Computing with Words in Decision Making*. Springer International Publishing, 2015. [Online]. Available: <https://books.google.es/books?id=zqwvCwAAQBAJ>
- [8] L. A. Zadeh, "Fuzzy logic= computing with words," *IEEE transactions on fuzzy systems*, vol. 4, no. 2, pp. 103–111, 1996.
- [9] F. Herrera and L. Martínez, "A 2-tuple fuzzy linguistic representation model for computing with words," *IEEE Transactions on fuzzy systems*, vol. 8, no. 6, pp. 746–752, 2000.
- [10] C. R. Graham, "Blended learning systems," *The handbook of blended learning*, pp. 3–21, 2006.
- [11] N. Cavus and T. Zabadi, "A comparison of open source learning management systems," *Procedia-Social and Behavioral Sciences*, vol. 143, pp. 521–526, 2014.
- [12] H. Setiaji and I. V. Papatungan, "Design of telegram bots for campus information sharing," in *IOP Conference Series: Materials Science and Engineering*, vol. 325, no. 1. IOP Publishing, 2018, p. 012005.
- [13] L. A. Zadeh, "The concept of a linguistic variable and its application to approximate reasoning—i," *Information sciences*, vol. 8, no. 3, pp. 199–249, 1975.
- [14] E. Cables, M. S. García-Cascales, and M. T. Lamata, "The Itopsis: An alternative to topsis decision-making approach for linguistic variables," *Expert Systems with Applications*, vol. 39, no. 2, pp. 2119–2126, 2012.
- [15] C.-T. Chen and W.-Z. Hung, "Applying fuzzy linguistic variable and electre method in r&d project evaluation and selection," in *Industrial Engineering and Engineering Management, 2008. IEEM 2008. IEEE International Conference on*. IEEE, 2008, pp. 999–1003.
- [16] G. J. Klir and B. Yuan, "Fuzzy sets and fuzzy logic: theory and applications," *Possibility Theory versus Probab. Theory*, vol. 32, no. 2, 1996.
- [17] R. R. Yager, "A new methodology for ordinal multiobjective decisions based on fuzzy sets," in *Readings in Fuzzy Sets for Intelligent Systems*. Elsevier, 1993, pp. 751–756.

**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 3:  
SISTEMAS BASADOS EN  
REGLAS DIFUSAS







# Relevancia, Precisión e Interpretabilidad en Sistemas Basados en Reglas Difusas

Marta Galende  
*CARTIF Centro Tecnológico*  
 Boecillo, Valladolid, España  
 margal@cartif.es

M. Isabel Rey  
*INDOMAUT S.L.*  
 Valladolid, España  
 i.rey@indomaut.com

M.J. Fuente  
*Dpto. Ingeniería de Sistemas y Automática*  
*Universidad de Valladolid*  
 Valladolid, España  
 mjfuente@eii.uva.es

G.I. Sainz-Palmero  
*Dpto. Ingeniería de Sistemas y Automática*  
*Universidad de Valladolid*  
 Valladolid, España  
 gresai@eii.uva.es

**Resumen**—Los Sistemas Basados en Reglas Difusas (SBRD) permiten modelar problemas reales, manejando no solo la no precisión en lo referente al conocimiento a manejar, sino también la precisión con la que modelan el problema y la capacidad para “interpretar” su comportamiento. Por otro lado aparece el concepto de relevancia de las reglas difusas del SBRD, parece que lo idóneo es que sus reglas sean relevantes, o lo más relevantes posible. Relevancia, precisión e interpretabilidad son las tres métricas que se consideran, y analizan, en este trabajo para conseguir SBRDs que presenten buenas prestaciones respecto a estos tres objetivos, centrándonos finalmente en cómo es la relevancia de las reglas de los SBRD en el equilibrio precisión-interpretabilidad.

Basándose en Transformaciones Ortogonales (SVD, PQR, OLS) es posible estimar la *Relevancia* de una regla difusa, y analizar como influye dicho valor en la búsqueda del equilibrio precisión-interpretabilidad en un SBRD. Usando nueve conjuntos de datos del repositorio KEEL, dos algoritmos de modelado: uno aproximativo (FasArt) y otro lingüístico (NefProx), y siguiendo una estrategia de optimización multi-objetivo (SPEA2), se presentan a continuación los resultados obtenidos que muestran el concepto de relevancia como un factor importante, y contradictorio, a tener en cuenta a la hora de generar SBRD.

**Index Terms**—Relevancia, Transformación Ortogonal, Precisión-Interpretabilidad, Sistemas Basados en Reglas Difusas

## I. INTRODUCCIÓN

Los Sistemas Difusos Basados en Reglas (SBRD) son una forma muy habitual de aplicar la lógica difusa tanto en áreas de investigación como para abordar problemas del mundo real [1]–[3]. Existen múltiples aproximaciones para generar estos SBRDs [4], [5], y una de las cuestiones a afrontar es cómo evaluar sus prestaciones: en este punto, las metodologías lingüísticas y precisas para la generación de SBRD [6]–[8] son las más usadas y debatidas.

Este aspecto ha sido ampliamente discutido: la Precisión es un aspecto básico para un modelo, difuso o no, pero además cuando la Lógica Difusa es utilizada aparecen otros puntos de

vista, como la capacidad para expresar, representar y explicar conocimiento en términos lingüísticos, similares a los usados por las personas. Este punto de vista es intrínseco a los principios de la Lógica difusa.

¿Cómo estimar la prestación de un SBRD? este es un aspecto básico tanto en desarrollos teóricos, como en aplicaciones prácticas, donde un modelo basado en SBRD tiene que ser perfectamente claro y definido. Por tanto, aprovechando las prestaciones de la Lógica Difusa, la obtención de un SBRD con una adecuada Interpretabilidad es de gran interés, pero siempre que el modelo implementado mediante un SBRD sea suficientemente preciso, sin este nivel de precisión cualquier modelo no es útil. Así, buscamos alcanzar modelos usando SBRD que puedan aunar Precisión e Interpretabilidad. Esto es lo que se conoce habitualmente como equilibrio Precisión-Interpretabilidad, aspectos que habitualmente se consideran mutuamente contraproducentes y contradictorios [7], [9]. ¿Cómo conseguirlo?, esto es una cuestión abierta, y múltiples aproximaciones y propuestas se pueden encontrar en la bibliografía especializada, como los sistemas genéticos difusos y la selección de reglas [6], [10]–[14], considerando distintas métricas de complejidad o semántica [15]–[18], etc.

En este ámbito, la propuesta aquí planteada se centra en el equilibrio Precisión - Interpretabilidad considerando una metodología basada en la selección de reglas, eligiendo estas reglas de acuerdo a las métricas de Precisión, Interpretabilidad, y añadiendo Relevancia. En la mayoría de los casos, la Relevancia se ha empleado para reducir la complejidad de los SBRD [19], [20], que está relacionada con la Interpretabilidad, pero aquí la Relevancia es un factor a considerar tan importante como la Precisión o la Interpretabilidad.

El resto del artículo se organiza como sigue: la sección II presenta el concepto de relevancia, su definición y posibles métricas a utilizar. La sección III muestra el problema de la búsqueda de equilibrio precisión-interpretabilidad en los SBRD y la sección IV presenta la metodología propuesta. La sección V muestra los resultados obtenidos en la parte expe-

Trabajo realizado gracias al soporte del Ministerio de Economía y Competitividad español y al European Regional Development Fund (FEDER) a través del proyecto no. DPI2015-67341-C2-2-R.

rimental y finalmente la sección VI presenta las principales conclusiones obtenidas y los futuros trabajos a realizar.

## II. RELEVANCIA

La relevancia de las reglas difusas se ha definido habitualmente mediante transformaciones ortogonales [21] como *Single Value Descomposition* (SVD), *Pivoting-QR* (PQR) o *Orthogonal Least Square* (OLS) aplicada sobre la matriz de activación de las reglas difusas, de forma similar a otras áreas como selección y extracción de características en reconocimiento de patrones. En SVD y PQR solo se tiene en cuenta la activación de los antecedentes de las reglas, mientras que en OLS también se considera el consecuente de las mismas. Como resultado de estas descomposiciones se obtienen estimaciones de la relevancia en forma de valores singulares, R-Values o varianzas de cada regla difusa para el problema dado [20], [22], [23].

## III. EQUILIBRIO PRECISIÓN-INTERPRETABILIDAD

La prestación de un SBRD se puede analizar bajo un doble punto de vista:

- **Precisión:** o capacidad para emular el comportamiento del sistema modelado. Métrica: *Error* [24].
- **Interpretabilidad:** capacidad para “explicar” su comportamiento o de la realidad que modelan. Métrica: existes diversas opciones [15]–[18].

En el proceso de modelado se necesita conseguir la suficiente precisión para que el modelo resultante sea útil, pero en el caso de SBRD además se puede optar a alcanzar un grado de interpretabilidad del mismo. Esto es el equilibrio precisión-interpretabilidad, que es el objetivo de este trabajo.

## IV. PRECISIÓN, INTERPRETABILIDAD Y RELEVANCIA EN SBRD

Siguiendo la metodología resumida en la Fig. 1 [10] se busca una mejora en la prestación del SBRD a través de un post-procesamiento basado en selección de sus reglas: la idea básica es buscar un equilibrio entre la precisión y la interpretabilidad considerando las reglas más relevantes del SBRD. En esta ocasión se aborda la estrategia de descartar las reglas menos relevantes durante el proceso.

*Fase 1:* generación de SBRDs de diferente naturaleza [25] en base a conjuntos de datos.

- Aproximativos: FasArt [26].
- Lingüísticos: NefProx [27].

Mediante las conocidas transformaciones ortogonales: SVD, PQR y OLS, se estima la relevancia de cada una de las reglas de los SBRD generados.

*Fase 2:* proceso de selección de reglas del SBRD que busca mejorar su Precisión-Interpretabilidad-Relevancia. Esto se realiza mediante el Algoritmo Evolutivo Multi-Objetivo (AEMO) SPEA2 [28].

Para esto los objetivos comprometidos son:

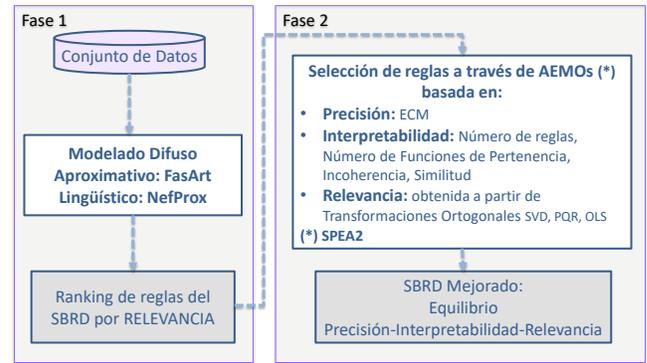


Figura 1. Mejora del equilibrio precisión-interpretabilidad de un SBRD mediante precisión, interpretabilidad y relevancia.

- Maximizar la precisión del sistema, minimizando el error cuadrático medio (Ec. 1).

$$ECM = \frac{1}{|N|} \sum_{i=1}^{|N|} (F(x_i) - y_i)^2 \quad (1)$$

- Maximizar la interpretabilidad del sistema, minimizando el valor de uno de los siguientes índices:
  - Número de reglas (Ec. 2).

$$NR = \text{Numero de reglas} \quad (2)$$

- Número de funciones de pertenencia (Ec. 3).

$$NMF = \text{Numero de funciones de pertenencia} \quad (3)$$

- Incoherencia de la base de reglas (Ec. 4).

$$Inc = \frac{|(S_{kA}(R_i, R_j) > (1 - \beta_I) \text{ AND } S_{kC}(R_i, R_j) < \beta_I)|}{(\text{Numero de Reglas} - 1)!}$$

$$\forall 1 \leq i < j \leq \text{Numero de Reglas}$$

$$\forall 1 \leq kA \leq \text{Numero de Antecedentes}$$

$$\forall 1 \leq kC \leq \text{Numero de Consecuentes} \quad (4)$$

- Similitud de la base de datos (Ec. 5).

$$Sim = F_{kA}(F_{l,m}(S(MF_{kA,l}, MF_{kA,m})))$$

$$F \Rightarrow \text{Media Aritmetica}$$

$$\forall 1 \leq l < m \leq \text{Numero de Funciones de Pertenencia}$$

$$\forall 1 \leq kA \leq \text{Numero de Antecedentes} \quad (5)$$

- Maximizar la relevancia de la relevancia del sistema, en este trabajo descartando las reglas menos relevantes (minimizando Ec. 6).

$$Rel_{RB} = \sqrt[k]{\prod_{i=1}^k (1 - Relevancia_{Regla_i})} \quad (6)$$

Esta metodología y las métricas utilizadas en detalle se pueden consultar en [10].



## V. TRABAJO EXPERIMENTAL

El impacto de relevancia en la búsqueda del equilibrio precisión-interpretabilidad se han comprobado mediante la experimentación que se detalla a continuación.

En [10] se muestran la estrategia de preservación de las reglas más relevantes, aquí se muestra, y analiza, la estrategia basada en descartar las reglas menos relevantes (Ec. 6).

### V-A. Casos de estudio

Se han utilizado nueve conjuntos de datos reales del proyecto KEEL [29] y una metodología de validación cruzada 5-fold. La Tabla I muestra las principales características de dichos conjuntos de datos.

Cuadro I  
CONJUNTOS DE DATOS CONSIDERADOS

Conjunto de datos	Nombre	Variables	Registros
Plastic Strength	PLA	3	1650
Quake	QUA	4	2178
Electrical Maintenance	ELE	5	1056
Abalone	ABA	9	4177
Stock prices	STP	10	950
Weather Izmir	WIZ	10	1461
Weather Ankara	WAN	10	1609
Mortgage	MOR	16	1049
Treasury	TRE	16	1049

El resto de opciones utilizadas en este trabajo han sido:

- Métrica de relevancia:  $Rel_{RB}$  descartando las reglas menos relevantes.
- Transformaciones Ortogonales: SVD, PQR y OLS.
- Algoritmos de modelado: FasArt como algoritmos aproximativo y NefProx como lingüístico, parametrizados según [11].
- Métricas de interpretabilidad:  $NR$ ,  $NMF$ ,  $Inc$  y  $Sim$  siguiendo las recomendaciones de [9], [15].
- Algoritmo evolutivo multi-objetivo:  $SPEA2$  utilizando codificación binaria, cruce HUX [30], mutación clásica [31] con probabilidad 0,2, mecanismo de prevención de incesto basado en los conceptos de CHC [30], operador de reinicialización y una población de padres que se va reduciendo progresivamente [32].

En cuanto a los planos de proyección de las soluciones finales [12], [33], [34] se presentan los resultados en el plano precisión-interpretabilidad, considerando el SBRD más preciso, el SBRD más interpretable, y SBRD en la mediana precisión-interpretabilidad.

### V-B. Análisis de resultados

La Tabla II muestra los resultados medios obtenidos para todos los conjuntos de datos cuando la relevancia se estima mediante la transformación OLS, analizando el plano precisión-interpretabilidad. Específicamente se muestran las siguientes métricas:  $NR$ ,  $NFP$ ,  $Inc$  y  $Sim$  como medidas de interpretabilidad;  $ECM$  en entrenamiento  $E_{tra}$  y test  $E_{tst}$ ; número de reglas  $NR$ ; métrica  $Rel_{RB}$  de relevancia optimizada y relevancia media  $Rel_{SD}$  de las reglas que permanecen en el sistema tras el proceso de optimización.

La Tabla III muestra los mismos resultados para SVD y la Tabla IV para PQR.

Realizando un análisis conjunto de las soluciones alcanzadas al aplicar los tres métodos de transformación ortogonal se puede decir que:

#### Modelado Aproximativo.

1. **Solución más precisa:** los valores medios de la *Interpretabilidad*, el *error*, el *número de reglas* y la *Relevancia* mejoran en todos los casos, hasta alcanzar una mejoría del 26,04 % en el primer caso, del 17,03 % en el segundo caso, del 26,32 % en el caso del número de reglas, y del 9,73 % en la Relevancia.
2. **Solución en la mediana Precisión-Interpretabilidad:** la *Interpretabilidad* ha mejorado hasta un 32,88 %, el *error* se reduce hasta un 16,36 %, el *número de reglas* también mejora siempre hasta el 34,99 %, y la *Relevancia* mejora hasta el 17,09 %.
3. **Solución más interpretable:** todas las métricas estudiadas han mejorado: la *Interpretabilidad* ha mejorado hasta un 51,67 %, el *error* se ha reducido hasta el 14,56 %, el *número de reglas* ha mejorado hasta un 43,53 %, y la *Relevancia* hasta el 30,04 %.

#### Modelado Lingüístico.

1. **Solución más precisa:** la *Interpretabilidad* ha mejorado hasta el 47,26 %, el *error* es reducido hasta el 36,36 %, el *número de reglas* mejora hasta un 47,32 %, y la *Relevancia* siempre mejora hasta el 24,91 %.
2. **Solución en la mediana Precisión-Interpretabilidad:** la *Interpretabilidad* se ve que mejora en casi todos los casos hasta conseguir un porcentaje de mejora del 51,28 %. Lo mismo sucede con el resto de métricas estudiadas que mejoran en todos los casos hasta alcanzar un porcentaje de mejora del 35,85 % en el caso del *error*, del 51,28 % en el caso del *número de reglas*, y del 27,18 % cuando lo analizado es la *Relevancia*.
3. **Solución más interpretable:** todas las métricas mejoran: la *Interpretabilidad* ha mejorado hasta un 62,74 %, el *error* hasta un 34,29 %, el *número de reglas* hasta un 56,48 %, y la *Relevancia* hasta alcanzar una importante mejoría del 47,98 %.

En cuanto al análisis de resultados en el resto de planos la Tabla V muestra un resumen de los valores obtenidos cuando se utiliza la transformación ortogonal OLS. Aquí las relaciones son más complejas y están en consonancia con la discusión en Sección V-C.

### V-C. Reglas relevantes y Precisión-Interpretabilidad

Un aspecto interesante a plantearse es ver y analizar cómo son las reglas del SBRD en el equilibrio precisión-interpretabilidad. En la metodología llevada a cabo, las reglas poco relevantes son las candidatas a no ser seleccionadas para el SBRD final. En la Tabla VI puede observarse la distribución de las reglas de los SBRD iniciales de acuerdo a su relevancia (normalizada en  $[0, 1]$  y clasificado en cuatro cuartos): en general la relevancia de las reglas presente en los modelos



Cuadro II  
VALORES MEDIOS (%) DE SBRDS MEJORADOS:  $Rel_{RB}$ , OLS, PLANO PRECISIÓN-INTERPRETABILIDAD

Inter	Mejor Pre						Mediana Pre-Inter						Mejor Inter					
	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$
<b>FasArt</b>																		
NR	25,88	19,64	16,61	25,88	0,13	8,01	30,60	18,67	15,79	30,60	0,27	14,00	38,12	7,68	5,96	38,12	0,57	25,65
NFP	25,14	19,63	16,71	26,26	0,13	8,40	31,57	17,47	14,83	32,90	0,34	17,09	40,82	-9,55	-7,28	41,79	0,68	30,04
Inc	-0,89	19,62	16,66	25,98	0,17	9,73	13,37	19,28	16,36	27,18	0,21	11,87	51,16	17,50	14,56	29,36	0,28	15,47
Sim	2,44	19,67	16,95	25,94	0,14	8,12	8,76	9,23	7,08	34,81	0,36	16,96	14,35	-39,77	-36,14	42,29	0,53	23,19
<b>NefProx</b>																		
NR	46,98	37,44	35,96	46,98	0,26	17,76	50,56	37,39	35,85	50,56	0,36	24,78	55,14	32,02	30,31	55,14	0,57	39,36
NFP	5,07	37,41	35,84	47,10	0,31	21,90	7,33	36,40	34,86	48,80	0,38	26,63	10,30	27,30	25,96	51,53	0,56	38,59
Inc	9,97	38,05	36,29	47,32	0,36	24,91	41,22	36,06	34,25	48,30	0,44	27,18	62,67	21,52	20,40	53,18	0,73	47,98
Sim	-4,71	37,36	35,85	46,68	0,30	20,68	-4,60	37,25	35,77	46,72	0,30	20,78	-3,87	35,53	34,25	47,30	0,37	25,67

Cuadro III  
VALORES MEDIOS (%) DE SBRDS MEJORADOS:  $Rel_{RB}$ , SVD, PLANO PRECISIÓN-INTERPRETABILIDAD

Inter	Mejor Pre						Mediana Pre-Inter						Mejor Inter					
	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$
<b>FasArt</b>																		
NR	25,83	19,63	16,68	25,83	0,04	2,05	30,72	17,91	15,10	30,72	0,10	4,61	38,47	2,11	0,64	38,47	0,22	9,71
NFP	24,94	19,67	16,74	26,04	0,04	2,18	31,18	17,79	14,83	32,62	0,13	6,11	40,81	-28,57	-23,94	41,80	0,26	11,14
Inc	0,64	19,64	16,49	25,75	0,05	2,65	14,72	19,25	16,12	26,97	0,05	3,17	51,67	17,19	13,98	29,11	0,08	4,59
Sim	2,22	19,58	16,69	25,83	0,05	2,51	8,97	9,55	6,15	34,99	0,13	5,43	14,69	-42,39	-38,72	42,80	0,22	8,31
<b>NefProx</b>																		
NR	46,59	37,51	35,87	46,59	0,06	6,63	50,00	37,33	35,76	50,00	0,13	11,63	55,31	33,39	32,08	55,31	0,28	21,54
NFP	5,19	37,56	35,90	46,53	0,07	7,27	7,51	35,52	33,82	48,56	0,12	10,61	10,85	25,80	24,06	51,19	0,20	16,96
Inc	11,49	38,18	36,36	46,01	0,09	9,36	40,95	36,34	34,49	47,84	0,13	13,61	62,74	21,75	20,25	52,16	0,24	21,55
Sim	-4,86	37,54	35,91	46,28	0,06	6,76	-4,49	37,08	35,68	46,40	0,07	7,18	-3,86	35,59	34,29	46,90	0,09	8,66

Cuadro IV  
VALORES MEDIOS (%) DE SBRDS MEJORADOS:  $Rel_{RB}$ , PQR, PLANO PRECISIÓN-INTERPRETABILIDAD

Inter	Mejor Pre						Mediana Pre-Inter						Mejor Inter					
	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$
<b>FasArt</b>																		
NR	26,04	19,63	16,80	26,04	0,04	2,62	31,77	17,40	14,91	31,77	0,09	5,08	39,96	-4,56	-5,53	39,96	0,20	9,89
NFP	25,26	19,65	16,75	26,32	0,04	2,47	32,88	16,06	13,25	34,01	0,11	5,77	42,70	-35,05	-29,01	43,53	0,24	11,19
Inc	-0,96	19,62	16,82	26,08	0,04	2,82	15,83	19,19	16,25	27,09	0,05	3,30	49,22	17,27	14,31	29,18	0,07	4,73
Sim	2,42	19,62	17,03	25,92	0,04	2,67	8,91	9,83	7,63	34,48	0,11	5,02	14,54	-40,03	-37,78	42,69	0,21	8,63
<b>NefProx</b>																		
NR	47,26	37,20	35,61	47,26	0,05	2,48	51,28	37,10	35,56	51,28	0,09	5,13	56,48	22,64	21,31	56,48	0,18	12,42
NFP	5,20	37,34	35,73	47,24	0,06	2,71	7,38	36,03	34,46	48,97	0,08	4,08	10,30	27,15	25,52	51,72	0,12	6,92
Inc	14,02	37,94	36,18	45,25	0,06	3,31	41,87	35,86	34,06	46,82	0,08	5,71	62,62	19,08	17,95	50,26	0,13	9,80
Sim	-4,77	37,36	35,75	46,73	0,05	2,53	-4,68	37,15	35,52	46,80	0,05	2,60	-4,15	35,06	33,71	47,32	0,06	3,16

Cuadro V  
VALORES MEDIOS (%) DE SBRDS MEJORADOS:  $Rel_{RB}$ , OLS, PLANOS Pre- $Rel_{RB}$  (PR),  $Rel_{RB}$ -Inter (RI)

Modelo	Inter	PR	Mejor Pre						Mediana Pre- $Rel_{RB}$						Mejor $Rel_{RB}$					
		RI	Mejor $Rel_{RB}$						Mediana $Rel_{RB}$ -Inter						Mejor Inter					
		Plano	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$	Inter	$E_{tra}$	$E_{lst}$	NR	$Rel_{RB}$	$Rel_{SD}$
FasArt	NR	PR	25,92	19,63	16,70	25,92	0,07	4,23	30,87	18,00	15,03	30,87	0,18	8,95	37,90	3,44	1,90	37,90	0,39	17,01
		RI	37,90	3,43	1,89	37,90	0,39	17,01	38,05	2,87	1,26	38,05	0,39	16,93	38,85	-1,29	-2,56	38,85	0,36	15,98
	NFP	PR	25,11	19,65	16,73	26,21	0,07	4,35	31,12	17,29	14,45	32,76	0,23	11,00	39,41	-2,35	-3,28	41,17	0,48	21,05
		RI	39,42	-2,37	-3,30	41,17	0,48	21,05	40,01	-5,71	-6,08	41,45	0,47	20,54	41,44	-27,04	-22,76	42,43	0,42	18,28
	Inc	PR	-0,64	19,63	16,66	26,03	0,09	5,18	0,95	18,33	15,52	31,28	0,22	11,11	32,29	7,88	5,78	37,82	0,43	19,57
		RI	32,29	7,88	5,78	37,82	0,43	19,57	39,94	8,01	5,78	37,39	0,42	18,91	50,68	7,78	5,62	37,32	0,41	18,02
Sim	PR	2,36	19,62	16,89	25,89	0,08	4,43	3,50	13,81	11,91	35,56	0,34	16,83	7,60	-21,72	-21,45	45,50	0,66	30,42	
	RI	2,31	19,62	16,89	25,94	0,08	4,50	11,35	-28,18	-27,11	44,02	0,54	24,85	14,53	-40,79	-37,61	42,63	0,32	13,40	
NefProx	NR	PR	46,91	37,38	35,81	46,91	0,13	9,17	50,51	37,21	35,67	50,51	0,22	16,51	55,21	28,38	26,81	55,21	0,39	28,03
		RI	55,21	28,37	26,79	55,21	0,39	28,03	55,30	28,37	26,79	55,30	0,39	27,89	55,65	27,42	25,96	55,65	0,36	25,66
	NFP	PR	5,15	37,44	35,83	46,98	0,15	10,65	5,76	37,14	35,51	51,96	0,30	21,85	8,94	21,86	20,05	57,37	0,56	39,98
		RI	8,96	21,83	20,01	57,37	0,56	39,98	9,35	22,94	21,34	57,35	0,55	39,33	10,49	21,99	20,41	57,08	0,51	36,48
	Inc	PR	11,68	38,05	36,28	46,24	0,17	12,61	10,05	35,73	33,95	52,87	0,54	40,09	37,54	6,28	5,05	58,02	0,91	66,73
		RI	37,57	6,24	5,00	58,02	0,91	66,73	47,62	4,21	3,07	57,20	0,85	61,10	62,68	0,61	-0,51	56,99	0,75	51,88
Sim	PR	-4,78	37,42	35,83	46,56	0,14	9,99	-5,40	37,22	35,67	50,35	0,25	18,68	-6,11	26,97	25,21	54,82	0,45	31,98	
	RI	-4,79	37,42	35,84	46,59	0,14	10,05	-5,45	27,57	25,92	54,73	0,43	31,14	-3,96	29,03	27,62	54,46	0,41	29,62	



difusos es baja, 60% – 90%, si se considera las reglas con relevancia Baja y MediaBaja la cifra está entre el 88% y casi el 100%. En el SBRD lingüístico las cifras son algo mayores que en el aproximativo, lo cual podría ser algo sorprendente.

Estos resultados implican que en los SBRD resultantes de esta metodología, que presentarán una mejora en el equilibrio precisión-interpretabilidad, las reglas con baja relevancia van a tener, y tienen, un destacado impacto tanto cualitativamente, como cuantitativamente. Por otro lado, aproximaciones muy conocidas para la simplificación de modelos difusos como [23], [35], [36] basadas en las reglas con relevancia “alta”, o punto de ruptura en los valores de relevancia, parecen ser de difícil aplicación real si además se analizan las magnitudes de las relevancias.

En la Tabla VII se puede observar la distribución de reglas por su relevancia en el SBRD optimizado para los modelos aproximativo y lingüístico, considerando las 4 métricas de interpretabilidad, en tres puntos de optimización: mejor precisión, mejor interpretabilidad y mediana precisión-interpretabilidad. También aparece el % de las reglas del modelo inicial, de acuerdo a su relevancia, que NO han sido seleccionadas en el SBRD final. Todo esto considerando la transformación OLS para la estimación de las relevancias.

En general, estos SBRD han aumentado su ratio de reglas consideradas de baja relevancia, ahora es mayor:  $\geq 92\%$ , siendo algo mayor para el SBRD lingüístico. Esto es coherente con la presencia de reglas poco relevantes en el SBRD de partida, incluso teniendo en cuenta que entre el 40 – 50% de ellas han sido descartadas. Más relevante en este descarte en lo referente a reglas con Alta, MediaAlta, MediaBaja relevancia: una parte importante de estas reglas, incluidas las de alta relevancia, no son, sorprendentemente, mantenidas en el SBRD. Este aspecto resulta contraproducente: reglas con la relevancia alta no son seleccionadas en 38 – 10%, alrededor del 60% MediaAlta, etc... pero también, como se observa en las Tablas II, III y IV la relevancia de las reglas de los SBRD finalmente obtenidos ha aumentado en todos los modelos y métricas de interpretabilidad.

Aquí, de acuerdo a los resultados, se ha comprobado que la relevancia de las reglas aporta en el proceso de mejora de la precisión e interpretación preservando en el SBRD las reglas más relevantes compatibles con esto. Considerando todo lo anterior, hay una cuestión básica a afrontar: la necesidad comprender el por qué de la no selección de reglas estimadas con relevancia alta, o incluso más alta que la mayoría de aquellas que si se mantienen en el modelo. Esto implica una caracterización de estas reglas no seleccionadas a pesar de su relevancia importante para dar respuesta a preguntas como: ¿Cómo son? ¿Por qué no son seleccionadas?, así poder generar algún criterio que permita estimar o no una regla para un SBRD.

## VI. CONCLUSIONES

En este trabajo se presentan los resultados obtenidos a partir de una metodología mostrada en [10] pero introduciendo el criterio de descartar las reglas difusas menos relevantes

Cuadro VI  
DISTRIBUCIÓN EN % DE REGLAS POR RELEVANCIA EN EL SBRD INICIAL

	SBRD	R_Baja	R_MediaBaja	R_MediaAlta	R_Alta
SVD	FasArt	70.24	23.35	5.36	1.06
	NefProx	88.60	6.53	3.40	1.47
PQR	FasArt	60.54	27.97	9.25	2.24
	NefProx	84.57	9.08	2.00	4.35
OLS	FasArt	94.55	4.45	0.91	0.09
	NefProx	97.54	1.98	0.36	0.12

Cuadro VII  
DISTRIBUCIÓN EN % DE LAS REGLAS POR RELEVANCIA DEL SBRD OPTIMIZADO CONSIDERANDO LA TRANSFORMACIÓN ORTOGONAL OLS: DISTRIBUCIÓN DE REGLAS POR SU RELEVANCIA, Y REGLAS NO SELECCIONADAS DEL MODELO INICIAL

Inter	Modelo	SBRD	Reglas	R_Baja	R_MediaBaja	R_MediaAlta	R_Alta
NR	Mejor Inter	FasArt	SBRD	92.50	6.66	0.77	0.07
		NoSelec.	39.36	11.12	33.25	38.89	
		NefProx	SBRD	96.35	3.05	0.39	0.21
	Mejor Pre	NoSelec.	55.50	27.02	61.67	11.67	
		FasArt	SBRD	93.86	5.40	0.68	0.06
		NoSelec.	26.42	9.75	30.75	38.89	
	Mediana	NefProx	SBRD	96.86	2.65	0.30	0.18
		NoSelec.	47.23	25.12	61.67	11.67	
		FasArt	SBRD	93.48	5.75	0.71	0.07
	Pre-Inter	NoSelec.	31.36	10.92	30.75	38.89	
		NefProx	SBRD	96.69	2.77	0.34	0.19
		NoSelec.	50.85	26.31	61.67	11.67	
NFP	Mejor Inter	FasArt	SBRD	92.06	7.09	0.77	0.08
		NoSelec.	43.21	12.91	31.03	41.67	
		NefProx	SBRD	96.36	3.04	0.40	0.19
	Mejor Pre	NoSelec.	51.89	24.05	61.67	10.00	
		FasArt	SBRD	93.87	5.41	0.66	0.07
		NoSelec.	26.81	9.94	29.36	41.67	
	Mediana	NefProx	SBRD	96.82	2.67	0.31	0.19
		NoSelec.	47.38	23.81	61.67	10.00	
		FasArt	SBRD	93.29	5.92	0.72	0.07
	Pre-Inter	NoSelec.	33.78	11.49	29.36	41.67	
		NefProx	SBRD	96.67	2.79	0.35	0.19
		NoSelec.	49.12	23.81	61.67	10.00	
INC	Mejor Inter	FasArt	SBRD	93.28	5.70	0.95	0.07
		NoSelec.	30.21	10.17	31.39	33.33	
		NefProx	SBRD	96.23	3.05	0.46	0.26
	Mejor Pre	NoSelec.	53.48	31.43	65.49	11.67	
		FasArt	SBRD	93.68	5.41	0.85	0.07
		NoSelec.	26.61	9.67	31.81	38.89	
	Mediana	NefProx	SBRD	96.80	2.64	0.35	0.20
		NoSelec.	47.53	32.86	61.67	11.67	
		FasArt	SBRD	93.54	5.50	0.89	0.07
	Pre-Inter	NoSelec.	27.87	9.87	31.39	33.33	
		NefProx	SBRD	96.83	2.58	0.35	0.24
		NoSelec.	48.51	33.33	62.71	10.00	
SIM	Mejor Inter	FasArt	SBRD	92.55	6.41	0.93	0.10
		NoSelec.	43.37	18.89	35.97	33.33	
		NefProx	SBRD	96.69	2.78	0.34	0.19
	Mejor Pre	NoSelec.	47.59	24.17	61.87	10.00	
		FasArt	SBRD	93.80	5.38	0.75	0.06
		NoSelec.	26.49	10.02	32.11	47.22	
	Mediana	NefProx	SBRD	96.85	2.66	0.30	0.19
		NoSelec.	46.94	24.40	62.71	10.00	
		FasArt	SBRD	93.21	5.86	0.85	0.08
	Pre-Inter	NoSelec.	35.69	14.12	33.19	38.89	
		NefProx	SBRD	96.85	2.66	0.30	0.19
		NoSelec.	46.99	24.40	62.71	10.00	

durante el proceso. Esto se ha traducido en la generación SBRD que, en general, mejoran sus prestaciones de precisión, interpretabilidad y relevancia en los modelos considerados: Mejor Precisión, Mejor Interpretabilidad y Mediana Precisión-Interpretabilidad. Analizando las reglas que son incluidas en esos modelos, se observa el hecho sorprendente de que reglas con una relevancia estimada alta, o al menos más alta que la mayoría de las seleccionadas, no son mantenidas en el SBRD. Conocer cómo son estas reglas, su caracterización y la razón de su no permanencia en el SBRD es una de las tareas actualmente en desarrollo. Por otro lado, estos modelos están formados de forma abrumadora por reglas consideradas poco relevantes, analizar que características tienen, y por qué son elegidas durante el proceso en contraposición a las relevantes

pero no que son eliminadas en el SBRD final, es la línea de trabajo a muy corto plazo.

## REFERENCIAS

- [1] J. Kacprzyk, W. Pedrycz, Springer Handbook of Computational Intelligence, Springer, 2015.
- [2] A. Konar, Computational Intelligence: Principles, techniques and applications, Springer-Verlag, Berlin, 2005.
- [3] F. O. Karray, C. d. De Silva, Soft Computing and Intelligent Systems Design. Theory, Tools and Applications, Addison Wesley, 2004.
- [4] J. Alcalá-Fdez, J. Alonso, A survey of fuzzy systems software: taxonomy, current research trends and prospects, IEEE Transactions on Fuzzy Systems 24 (1) (2016) 40 – 56.
- [5] L. Magdalena, Fuzzy Rule-Based Systems, in: Springer Handbook of Computational Intelligence, Springer, 2015, pp. 203 – 218.
- [6] A. Fernández, V. López, M. J. del Jesus, F. Herrera, Revisiting evolutionary fuzzy systems: Taxonomy, applications, new trends and challenges, Knowledge-Based Systems 80 (2015) 109–121.
- [7] J. Casillas, O. Cordón, F. Herrera, L. Magdalena, Accuracy improvements to find the balance interpretability-accuracy in fuzzy modeling: An overview, in: J. Casillas, O. Cordón, F. Herrera, L. Magdalena (Eds.), Accuracy Improvements in Linguistic Fuzzy Modelling, Vol. 129 of Studies in Fuzziness and SoftComputing, Springer-Verlag, Berlin Heidelberg, 2003, pp. 3–24.
- [8] J. Casillas, O. Cordón, F. Herrera, L. Magdalena, Interpretability improvements to find the balance interpretability-accuracy in fuzzy modeling: An overview, in: J. Casillas, O. Cordón, F. Herrera, L. Magdalena (Eds.), Interpretability Issues in Fuzzy Modelling, Vol. 128 of Studies in Fuzziness and SoftComputing, Springer-Verlag, Berlin Heidelberg, 2003, pp. 3–22.
- [9] J. M. Alonso, C. Castiello, C. Mencar, Interpretability of fuzzy systems: Current research trends and prospects, in: Springer Handbook of Computational Intelligence, Springer, 2015, pp. 219–237.
- [10] M. I. Rey, M. Galende, M. J. Fuente, G. I. S. Palmero, Multi-objective based fuzzy rule based systems (frbss) for trade-off improvement in accuracy and interpretability: A rule relevance point of view, Knowledge-Based Systems 127 (2017) 67–84. doi:10.1016/j.knosys.2016.12.028. URL <https://doi.org/10.1016/j.knosys.2016.12.028>
- [11] M. Galende, M. J. Gacto, G. Sainz, R. Alcalá, Comparison and design of interpretable linguistic vs. scatter FRBSs: Gm3m generalization and new rule meaning index for global assessment and local pseudo-linguistic representation, Information Sciences 282 (2014) 190–213.
- [12] M. Galende, G. I. Sainz, M. J. Fuente, Complexity reduction and interpretability improvement for fuzzy rule systems based on simple interpretability measures and indices by bi-objective evolutionary rule selection, Soft Computing 16 (3) (2012) 451 – 470.
- [13] M. Fazzolari, R. Alcalá, Y. Nojima, H. Ishibuchi, F. Herrera, A review of the application of multiobjective evolutionary fuzzy systems: Current status and further directions, IEEE Transactions on Fuzzy Systems 21 (2013) 45 – 65.
- [14] O. Cordón, A historical review of evolutionary learning methods for mamdani-type fuzzy rule-based systems: Designing interpretable genetic fuzzy systems, International Journal of Approximate Reasoning 52 (2011) 894 – 913.
- [15] M. J. Gacto, R. Alcalá, F. Herrera, Interpretability of linguistic fuzzy rule-based systems: An overview of interpretability measures, Information Sciences 181 (2011) 4340 – 4360.
- [16] J. M. Alonso, L. Magdalena, G. González-Rodríguez, Looking for a good fuzzy system interpretability index: An experimental approach, International Journal of Approximate Reasoning 51 (1) (2009) 115 – 134.
- [17] C. Mencar, A. Fanelli, Interpretability constraints for fuzzy information granulation, Information Sciences 178 (24) (2008) 4585 – 4618.
- [18] S.-M. Zhou, J. Q. Gan, Low-level interpretability and high-level interpretability: a unified view of data-driven interpretable fuzzy system modelling, Fuzzy Sets and Systems 159 (2008) 3091 – 3131.
- [19] S.-M. Zhou, J. M. Garibaldi, R. I. John, F. Chiclana, On constructing parsimonious type-2 fuzzy logic systems via influential rule selection, IEEE Transactions on Fuzzy Systems 17 (3) (2009) 654 – 667.
- [20] M. Setnes, Simplification and reduction of fuzzy rules, in: J. Casillas, O. Cordón, F. Herrera, L. Magdalena (Eds.), Interpretability Issues in Fuzzy Modelling, Vol. 128 of Studies in Fuzziness and SoftComputing, Springer-Verlag, Berlin Heidelberg, 2003, pp. 278–302.
- [21] G. H. Golub, C. F. Van Loan, Matrix computations, Vol. 3, JHU Press, 2012.
- [22] S. Destercke, S. Guillaume, B. Charnomordic, Building an interpretable fuzzy rule base from data using orthogonal least squares - Application to a depollution problem, Fuzzy Sets and Systems 158 (18) (2007) 2078 – 2094.
- [23] J. Yen, L. Wang, Simplifying fuzzy rule-based models using orthogonal transformation methods, IEEE Transactions on Systems, Man and Cybernetics. Part B: Cybernetics 29 (1) (1999) 13–24.
- [24] I. H. Witten, E. Frank, M. A. Hall, Data Mining: Practical machine learning tools and techniques, 3rd Edition, Morgan Kaufmann, 2011.
- [25] F. Herrera, Genetic fuzzy systems: Taxonomy, current research trends and prospects, Evolutionary Intelligence 1 (2008) 27 – 46.
- [26] J. M. Cano Izquierdo, Y. A. Dimitriadis, E. Gómez Sánchez, J. López Coronado, Learning from noisy information in FasArt and Fasback neuro-fuzzy systems, Neural Networks 14 (4-5) (2001) 407–425.
- [27] D. Nauck, R. Kruse, Neuro-fuzzy systems for function approximation, Fuzzy Sets and Systems 101 (2) (1999) 261–271.
- [28] E. Zitzler, M. Laumanns, L. Thiele, SPEA2: Improving the strength pareto evolutionary algorithm for multiobjective optimization, in: Proc. Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems, Barcelona, Spain, 2001, pp. 95–100.
- [29] J. Alcalá-Fdez, L. Sánchez, S. García, M. J. del Jesus, S. Ventura, J. M. Garrell, J. Otero, C. Romero, J. Bacardit, V. M. Rivas, J. C. Fernández, F. Herrera, KEEL: a software tool to assess evolutionary algorithms for data mining problems, Soft Computing 13 (3) (2009) 307 – 318.
- [30] L. J. Eshelman, The CHC adaptive search algorithm : How to have safe search when engaging in nontraditional genetic recombination, Foundations of Genetic Algorithms 1 (1991) 265–283.
- [31] H. Ishibuchi, T. Murata, I. B. Türkmen, Single-objective and two-objective genetic algorithms for selecting linguistic rules for pattern classification problems, Fuzzy Sets and Systems 89 (2) (1997) 135 – 150.
- [32] R. Alcalá, M. J. Gacto, F. Herrera, J. Alcalá-Fdez, A multi-objective genetic algorithm for tuning and rule selection to obtain accurate and compact linguistic fuzzy rule-based systems, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems 15 (5) (2007) 539 – 557.
- [33] C. H. Nguyen, V. T. Hoang, V. L. Nguyenc, A discussion on interpretability of linguistic rule based systems and its application to solve regression problems, Knowledge-Based Systems 88 (2015) 107 – 133.
- [34] M. Antonelli, P. Ducange, B. Lazzarini, F. Marcelloni, Learning knowledge bases of multi-objective evolutionary fuzzy systems by simultaneously optimizing accuracy, complexity and partition integrity, Soft Computing 15 (12) (2011) 2335 – 2354.
- [35] M. Setnes, R. Babuška, Rule base reduction: Some comments on the use of orthogonal transforms, IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews 31 (2) (2001) 199 – 206.
- [36] R. Babuska, Fuzzy Modeling for Control, Kluwer Academic Press, 1998.



# Generación eficiente de reglas candidatas de calidad en problemas de alta dimensionalidad

Javier Cózar  
 Dept. de Sistemas Informáticos  
 Universidad of Castilla-La Mancha  
 Albacete, España  
 javier.cozar@uclm.es

Luis de la Ossa  
 Dept. de Sistemas Informáticos  
 Universidad of Castilla-La Mancha  
 Albacete, España  
 luis.delaossa@uclm.es

José Antonio Gámez  
 Dept. de Sistemas Informáticos  
 Universidad of Castilla-La Mancha  
 Albacete, España  
 jose.gamez@uclm.es

**Resumen**—Existen multitud de métodos para la generación de modelos basados en reglas difusas a partir de conjuntos de datos. Debido a que el número de reglas que puede generarse es exponencial con respecto al número de variables, los algoritmos se suelen apoyar en técnicas de búsqueda, generalmente metaheurísticas, para determinar qué reglas componen el sistema final. Aún así, sigue siendo necesario reducir el conjunto de reglas candidatas de manera sustancial. En esta línea, existen métodos que generan un primer conjunto de reglas, y posteriormente lo filtran mediante un algoritmo iterativo, basándose en criterios de calidad y genericidad. Sin embargo, este proceso es muy costoso. En este trabajo proponemos un método de generación de reglas candidatas de una sola etapa, basado en el principio Apriori, y que incorpora el uso de una métrica de calidad. Hemos llevado a cabo una experimentación con 7 problemas de regresión, desde 16 hasta 80 variables. Los resultados muestran un buen comportamiento en términos de precisión, y una mejora muy notable en cuanto a los tiempos de ejecución.

**Index Terms**—Sistemas Basados en Reglas Difusas, Regresión, Takagi Sugeno Kang, Alta dimensionalidad

## I. INTRODUCCIÓN

Los sistemas basados en reglas difusas (SBRDs) [1]–[3] son modelos compuestos por un conjunto de reglas del tipo “Si *antecedente* entonces *consecuente*”. Su expresividad radica en que los espacios de entrada que activan distintas reglas pueden solaparse, por lo que una entrada generalmente activa más de una regla, y la predicción del modelo se obtiene mediante la composición de las salidas correspondientes.

La ventaja de los SRBDs se centra en dos aspectos. Por un lado, son modelos altamente interpretables, por lo que proporcionan al experto información relativamente clara sobre las relaciones que existen en los datos, además de permitir la incorporación de conocimiento externo antes o durante el proceso de aprendizaje. Por otro lado, estos modelos trabajan de forma inherente con la incertidumbre asociada a los datos, por lo que son muy robustos.

Muchos SBRDs representan la información mediante un conjunto de variables difusas, y un conjunto de reglas difusas construidas a partir de estas variables. Esta división da lugar, principalmente, a dos tipos de algoritmos para el aprendizaje de SRBDs: los que aprenden el conjunto de variables difusas (las particiones) y la base de reglas simultáneamente; y los que aprenden la base de reglas una vez establecido el conjunto de variables difusas.

Este trabajo propone un método que parte de un conjunto de variables difusas previamente establecido, y lleva a cabo el aprendizaje de la base de reglas difusas, en problemas de (relativamente) alta dimensionalidad. En concreto, para reglas TSK-0, cuyo consecuente es un número real. El aprendizaje de SBRDs es un proceso costoso debido, principalmente, a la explosión combinatoria de reglas: en un problema con  $n$  variables, y en el que cada variable difusa se define mediante una partición con  $k$  conjuntos difusos, pueden generarse hasta  $k^{(n+1)} - 1$  reglas diferentes. Este hecho, hace impracticable trabajar con el conjunto completo de posibles reglas. Por ello se suele dividir el proceso de aprendizaje en dos etapas [4], [5]: 1) generación de un conjunto de reglas candidatas; y 2) uso de un algoritmo de búsqueda para determinar el subconjunto de reglas que componen el modelo final.

La generación de reglas candidatas tiene un impacto crítico tanto en el rendimiento (error) del modelo, como en el coste del proceso de aprendizaje. Una estrategia para llevarla a cabo consiste en generar, en una primera fase, aquellas reglas candidatas que tienen mayor relevancia en relación a la cobertura de las instancias del conjunto de datos. Para ello, se utilizan algoritmos basados en el principio Apriori [6]. Posteriormente, en una segunda fase, y mediante un proceso iterativo, se seleccionan aquellas reglas de mayor calidad, minimizando el solapamiento entre las reglas seleccionadas en la medida de lo posible. Este enfoque permite abordar el problema en entornos de alta dimensionalidad. Sin embargo, la primera fase, basada en el algoritmo Apriori, genera todavía un número demasiado elevado de reglas, por lo que la posterior selección es excesivamente costosa. En este trabajo proponemos unificar ambas fases, incorporando una métrica de calidad monótona al proceso basado en el principio Apriori, que permita obtener el conjunto de reglas candidatas de manera más eficiente.

La estructura de este trabajo se divide en 4 secciones además de esta introducción. En la Sección II se describen los SBRDs y, en particular, los basados en reglas tipo TSK de orden cero. En la Sección III se describirá cómo se afronta el problema de la generación de reglas candidatas en trabajos previos, y la propuesta que se expone en este trabajo para realizarlo de una forma más eficiente. Posteriormente, en la Sección IV, se detallará la configuración y los resultados de los experimentos. Por último, en la Sección V, se expondrán las conclusiones.

## II. SISTEMAS BASADOS EN REGLAS DIFUSAS TSK-0

Los SBRDs de tipo *Takagi-Sugeno-Kang* (TSK) [7] son modelos compuestos por: un conjunto de variables difusas [1], que se caracteriza por los conjuntos y etiquetas lingüísticas en que se particiona cada una de ellas [8]; y una base de reglas definida sobre estas variables. El consecuente de cada regla TSK es una función polinomial de las variables de entrada y, en el caso de los sistemas de orden cero (TSK-0) el consecuente es un polinomio de orden cero, es decir, un número real.

El antecedente de una regla difusa está formado por uno o varios predicados de la forma  $X$  es  $F$ , donde  $X$  es una variable del problema y  $F$  es un conjunto difuso incluido en la partición asociada a la variable  $X$ . De esta forma, una regla de tipo TSK-0 se representa:

$$R_s : \text{Si } X_1 \text{ es } F_1^s \text{ y } \dots \text{ y } X_n \text{ es } F_n^s \text{ entonces } Y = b_s$$

La regla describe una relación entre las variables de entrada y la salida. Dada una instancia  $e_l = (x_1^l, x_2^l, \dots, x_n^l)$ , el proceso de inferencia asocia un grado de verdad  $h_s^l$  a la salida de la regla  $b_s$ , donde  $h_s^l = T(\mu_{X_1}^{x_1^l}, \mu_{X_2}^{x_2^l}, \dots, \mu_{X_n}^{x_n^l})$ , siendo  $T$  una T-norma<sup>1</sup>. Debido a que una misma instancia puede disparar varias reglas, la inferencia en los SBRDs de tipo TSK obtiene la salida,  $\hat{y}^l$ , como la media de las salidas individuales generadas por cada regla  $R_s \in \mathcal{RB}$ , ponderada por su grado de verdad (ver Ecuación 1).

$$\hat{y}^l = \frac{\sum_{R_s \in \mathcal{RB}} h_s^l b_s}{\sum_{R_s \in \mathcal{RB}} h_s^l} \quad (1)$$

## III. GENERACIÓN DE REGLAS CANDIDATAS TSK-0 EN PROBLEMAS DE ALTA DIMENSIONALIDAD

Los algoritmos que aprenden SBRDs partiendo de una definición de las variables difusas, suelen dividir la tarea en la generación de un conjunto de reglas candidatas, y la posterior selección del subconjunto de reglas y ajuste del consecuente de las mismas [4], [5], [9], [10]. Este trabajo se centra en la fase de extracción de reglas candidatas, por lo que puede ser aplicado a cualquier algoritmo que utilice esta estrategia.

Como nos centraremos únicamente en la construcción del conjunto de reglas candidatas, utilizaremos un algoritmo que genera la partición de las variables difusas en un solo paso. En trabajos relacionados se utiliza comunmente una distribución de los conjuntos difusos triangulares de igual anchura (ver Figura III). Sin embargo, este enfoque puede ser inadecuado cuando los datos no están distribuidos homogéneamente a lo largo del dominio de la variable, ya que la importancia de cada conjunto difuso sería diferente al cubrir una proporción desigual del número de instancias del problema. La alternativa que utilizamos en este trabajo consiste en distribuir estos conjuntos difusos triangulares de forma equifrecuencial, de tal manera que cada conjunto cubra el mismo porcentaje de instancias del problema (ver Figura 2).

<sup>1</sup>En este trabajo usamos *min* como T-Norma.

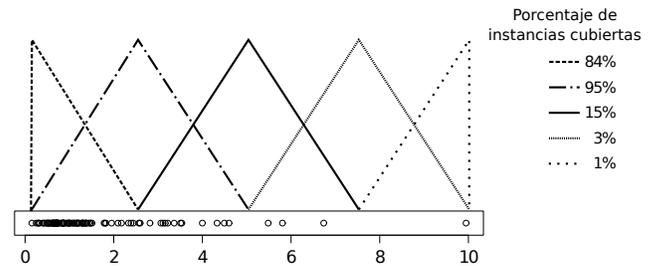


Figura 1. Particiones difusas con distribución equiespacial

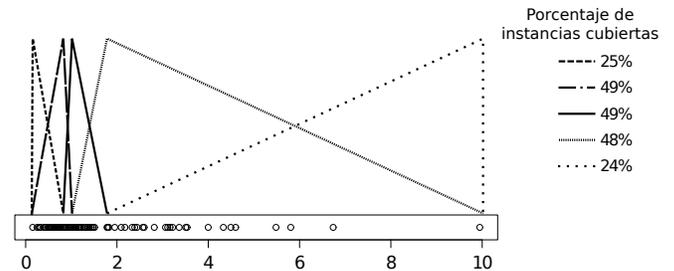


Figura 2. Particiones difusas con distribución equifrecuencial

De cara a seleccionar el subconjunto de reglas candidatas y fijar su consecuente, utilizaremos el algoritmo básico del estado del arte en sistemas TSK-0 [11]. Éste consiste en seleccionar el conjunto completo de reglas candidatas y, utilizando mínimos cuadrados, estimar sus consecuentes de forma que se minimice el error del sistema completo de reglas con respecto al conjunto de datos de entrenamiento  $\mathcal{E}$ . La expresión matricial utilizada por el método de mínimos cuadrados se muestra en la Ecuación 2, donde  $c_s^l = \frac{h_s^l}{\sum_{R_s \in \mathcal{RB}} h_s^l}$ . El vector columna de consecuentes,  $[b_1, \dots, b_{|\mathcal{RB}|}]^T$ , se obtiene como  $B = C^{-1} \cdot Y$ , donde  $C^{-1}$  se calcula utilizando la pseudoinversa de Moore-Penrose construida a mediante el método SVD [12].

$$Y = C \cdot B = \begin{bmatrix} y^1 \\ \vdots \\ y^l \\ \vdots \\ y^{|\mathcal{E}|} \end{bmatrix} = \begin{bmatrix} c_1^1 & \cdots & c_{|\mathcal{RB}|}^1 \\ \vdots & \vdots & \vdots \\ c_1^l & \cdots & c_{|\mathcal{RB}|}^l \\ \vdots & \vdots & \vdots \\ c_1^{|\mathcal{E}|} & \cdots & c_{|\mathcal{RB}|}^{|\mathcal{E}|} \end{bmatrix} \cdot \begin{bmatrix} b_1 \\ \vdots \\ b_{|\mathcal{RB}|} \end{bmatrix} \quad (2)$$

Nuestra propuesta para la generación de reglas candidatas, parte del trabajo propuesto en [5], en el que se genera el conjunto de reglas candidatas TSK-0 en dos fases. En primer lugar, extrayendo aquellas que tienen una alta interacción con el conjunto de datos de entrenamiento; y posteriormente filtrando aquellas reglas que tienen un mínimo grado de calidad individual, medida como la varianza de dicha regla con respecto al conjunto de instancias que la activan. A continuación se detallan ambas etapas, y el método alternativo propuesto.

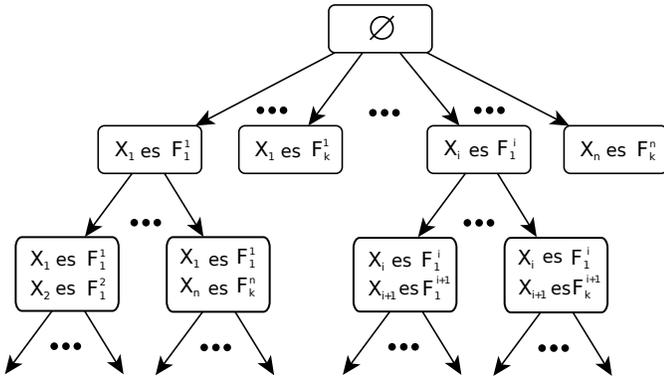


Figura 3. Estructura general del árbol de reglas candidatas

### III-A. Extracción de reglas candidatas

El proceso para la extracción de reglas difusas propuesto en [5] está basado en el conocido método *Apriori* para la extracción de reglas asociativas [6].

Un conjunto  $F_s = (F_i^s, \dots, F_j^s)$ , representa una serie de predicados  $X_i$  es  $F_i^s, \dots, F_j$  es  $F_j^s$ , tal que  $X_i \neq X_j \forall i, j$ . Visto de otra manera,  $F_s$  es la representación del antecedente de una regla candidata  $R_s$ . El soporte de un conjunto  $F_s$  cuantifica el número de ejemplos que emparejan con la regla, y en qué medida lo hacen. Se expresa como:

$$\text{soporte}(F_s) = \frac{\sum_{e_l} T(\mu_{F_i^s}^{x_i^l}, \dots, \mu_{F_j^s}^{x_j^l})}{|\mathcal{E}|} = \frac{\sum_{e_l} h_s^l}{|\mathcal{E}|}$$

Se denomina conjunto frecuente a aquel cuyo soporte es mayor que un umbral  $\text{min\_soporte}$ . El significado de este parámetro está asociado con el número de instancias que activan el antecedente de la regla asociada. De esta manera, si  $\text{min\_soporte} = 0,05$ , significa que el conjunto será frecuente si un 5% de las instancias están cubiertas por la regla asociada con grado de cobertura 1, o un mayor porcentaje si este grado de cobertura no es máximo para todas ellas.

El método de generación de reglas candidatas devuelve aquellas que superen el umbral de mínimo soporte. Para conseguirlo de manera eficiente, se construye un árbol de búsqueda [4] en el que cada nodo representa un conjunto o antecedente  $F^s$ , de modo que un nodo correspondiente al conjunto  $F^{s'}$  es hijo de otro, correspondiente al conjunto  $F^s$ , si  $F^{s'}$  se obtiene añadiendo un predicado a  $F^s$  (Figura 3).

El árbol se construye desde la raíz, y considerando el principio *apriori*, según el cual, si un nodo es no frecuente, ninguno de sus nodos hijos será frecuente, por lo que no es necesario expandirlo.

Si la métrica utilizada, en este caso el soporte, es monótonamente creciente o decreciente, el resultado del algoritmo es equivalente al devuelto a partir de una exploración completa del árbol. En el caso del soporte, éste es monotonamente

decreciente. Por convenio, se parte de un soporte inicial en el nodo raíz (regla sin antecedentes) igual a uno. Conforme se añaden predicados al antecedente vacío, el soporte solo puede disminuir.

### III-B. Filtrado de reglas candidatas

En problemas de alta dimensionalidad, el conjunto de reglas candidatas generado por el proceso anterior puede ser, todavía, excesivamente elevado. Esto se debe, en parte, a que muchas reglas son redundantes (cubren conjuntos muy parecidos de ejemplos). Además, las reglas son seleccionadas por cobertura, por lo que no se tiene en cuenta la capacidad de predicción de las mismas. Debido a esto, en una fase posterior, se han de elegir las mejores reglas dentro del conjunto total de reglas candidatas.

El proceso de filtrado, llamado *prescreening*, realiza una selección iterativa de las reglas candidatas basada en su calidad predictiva, y trata de evitar la redundancia entre ellas. La métrica utilizada para calcular la calidad individual de las reglas, es el error cuadrático medio de predicción de cada regla con respecto a las instancias la activan. Como los valores de esta métrica permanecen invariables a lo largo del proceso, son precalculados antes de comenzar el proceso iterativo. Para evaluar el grado de redundancia se mide, para cada instancia  $e_l$ , en la iteración  $i$ , el número de reglas ya seleccionadas que la activan, denotado como  $c_l^i$ . Para cada regla, se calcula entonces la media de los grados de activación con cada instancia del conjunto de datos, ponderada por el peso asociado a cada una de ellas, siendo éste  $w_l^i = \frac{1}{c_l^i + 1}$ . De esta manera, si una instancia está cubierta por varias reglas ya seleccionadas, la suma de los grados de activación ponderados disminuirá, favoreciendo la selección de otras reglas cuyo grado de redundancia es menor.

Inicialmente el conjunto de reglas candidatas preseleccionadas es  $\mathcal{RB}_c = \emptyset$ . En cada iteración,  $i$ , se seleccionará la mejor regla de acuerdo a la métrica expresada en la Ecuación 3, donde  $ECM(\mathcal{E}^s)$  es el error cuadrático medio de la variable objetivo para las instancias que activan la regla  $R_s$ . Dado que la parte que mide el grado de redundancia y el ECM tienen un dominio diferente, éstos se normalizan al rango  $[0-1]$  en cada iteración. Si todas las instancias están cubiertas un mínimo de  $k_t$  reglas, el proceso iterativo termina.

$$wWRAccR(R_s, i) = \sum_{e_l} \frac{w_l^i(e_l) \cdot h_s^l}{w_l^i(e_l)} \cdot ECM(\mathcal{E}^s) \quad (3)$$

### III-C. Propuesta de unificación de las fases de generación de reglas y filtrado

El coste del algoritmo de filtrado (*prescreening*) descrito anteriormente es muy elevado. Esto se debe, por una parte, a que el número de reglas generadas con *apriori* suele ser muy grande; por otra parte, en cada iteración se debe calcular, para cada instancia, el grado de cobertura con cada regla ponderado por el peso de dicha instancia. En este trabajo proponemos el diseño de una métrica que permita cuantificar

la calidad de una regla, y que sea monótonamente creciente o decreciente, de tal manera que se pueda integrar en la fase inicial de generación de reglas candidatas (basada en *apriori*), evitando el posterior uso de un algoritmo de filtrado.

Se puede comprobar fácilmente que el ECM no es una métrica montóna. Por ejemplo, supóngase el conjunto de valores  $Y = \{1, 2, 3, 2\}$ , y una predicción  $\hat{Y} = \{2, 2, 2, 2\}$ . En ese caso,  $ECM(Y, \hat{Y}) = \frac{2}{4}$ . Si se reduce el conjunto de instancias, de tal manera que  $Y' = \{1, 2, 3\}$ , y la predicción es  $\hat{Y}' = \{2, 2, 2\}$ ,  $ECM(Y', \hat{Y}') = \frac{2}{3}$ . Es decir, aumenta. Por otro lado, si el conjunto  $Y' = \{2, 2\}$ , y  $\hat{Y}' = \{2, 2\}$ , entonces  $ECM(Y', \hat{Y}') = \frac{0}{2}$ , es decir, el ECM se reduce.

Debido a esto, la métrica que se propone utilizar es el error cuadrático, que sí es monótonamente decreciente, al igual que el soporte. Sea  $N$  el número de instancias del conjunto de datos ( $N = |\mathcal{E}|$ ). Y sean  $\sum_{i=1}^N (y_i - \bar{y})^2$  el error cuadrático para  $N$  instancias ( $ECM_N$ ), y  $\sum_{i=1}^{N+1} (y_i - \bar{y})^2$  el análogo para  $N+1$  instancias ( $ECM_{N+1}$ ). Entonces,

$$ECM_N \leq ECM_{N+1}$$

$$\sum_{i=1}^N (y_i - \bar{y})^2 \leq \sum_{i=1}^N (y_i - (\bar{y} + \delta))^2 + (y_{N+1} + \delta)^2,$$

donde se expresa la media para las  $N+1$  instancias como la media para  $N$  instancias más una variación  $\delta$ . Para demostrar que la inecuación anterior siempre se satisface, se parte de que, como  $(y_{N+1} + \delta)^2$  es un número positivo, la expresión se puede simplificar a:

$$\sum_{i=1}^N (y_i - \bar{y})^2 \leq \sum_{i=1}^N (y_i - (\bar{y} + \delta))^2$$

$$\sum_{i=1}^N (y_i^2 + \bar{y}^2 - 2x\bar{y}) \leq \sum_{i=1}^N (y_i^2 + (\bar{y} + \delta)^2 - 2y(\bar{y} + \delta))$$

$$\sum_{i=1}^N (y_i^2 + \bar{y}^2 - 2x\bar{y}) \leq \sum_{i=1}^N (y_i^2 + \bar{y}^2 + \delta^2 + 2\bar{y}\delta - 2y\bar{y} - 2y\delta).$$

Restando la parte izquierda de la inecuación a ambos lados:

$$0 \leq \sum_{i=1}^N (\delta^2 + 2\bar{y}\delta - 2y\delta)$$

$$0 \leq N\delta^2 + 2N\bar{y}\delta - 2\delta \sum_{i=1}^N y_i.$$

La media de  $y_1, \dots, y_N, \bar{y}$  se puede expresar como:

$$0 \leq N\delta^2 + 2N\delta \frac{\sum_{i=1}^N y_i}{N} - 2\delta \sum_{i=1}^N y_i$$

$$0 \leq N\delta^2 + 2\delta \sum_{i=1}^N y_i - 2\delta \sum_{i=1}^N y_i$$

$$0 \leq N\delta^2,$$

siendo  $N$  siempre un número positivo, al igual que  $\delta^2$ . Por lo tanto, la inecuación se cumple siempre, por lo que se demuestra que el error cuadrático es monótono.

Utilizando el  $EC$  como métrica de calidad, se puede proceder de manera similar a como se hace con el soporte para la construcción del árbol de reglas candidatas. Es decir, puede fijarse un umbral máximo de  $EC$ , y solo las reglas que cumplen este criterio serán incluidas en  $\mathcal{RB}_c$  como reglas candidatas. Sin embargo, como las métricas de cobertura (soporte) y de calidad de predicción ( $EC$ ) son métricas contrapuestas (un valor alto de soporte es positivo, mientras que un valor alto de  $EC$  es negativo), no se pueden combinar para computar la decisión de podar o no una rama. Por ello, la solución que se adopta consiste en continuar con el mismo criterio de generación, basado únicamente en el soporte, y utilizar el  $EC$  como criterio para incluir o no la regla derivada del nodo en  $\mathcal{RB}_c$ .

En estudios preliminares se observó que el parámetro de máximo  $EC$  es muy dependiente del conjunto de datos, y debía ser ajustado específicamente. Para solucionar este problema, se aplica una técnica de poda selectiva sobre los nodos descendientes, en lugar de aplicarla a nivel de expansión de nodos. Cuando un nodo cumple el criterio de mínimo soporte, éste será considerado como regla candidata y será expandido, generando el conjunto de nodos descendientes. En este momento, se filtrarán estos nodos en función de la calidad *con respecto al padre*. En concreto, se descartarán los nodos cuyo  $EC$  dividido por el soporte de la regla  $R_s$  no disminuya en un porcentaje con respecto al  $EC$  del padre dividido por el soporte del nodo padre. El parámetro que determina este porcentaje se denomina *min\_quality\_improvement*. La intuición que sostiene este criterio (dividir el  $EC$  por el soporte de cada nodo) es la siguiente: un nodo puede ver disminuido el error cuadrático con respecto al padre simplemente por el hecho de que tiene menos instancias, pero aún así, los datos correspondientes (los que emparejan la regla) presentan la misma dispersión. Por ello, dividiendo la división por el soporte, constituye una buena métrica para indicar el porcentaje de mejora con respecto al padre.

#### IV. EXPERIMENTACIÓN

Para validar la calidad de las reglas candidatas generadas, se comparará la estrategia expuesta en [5] y la propuesta descrita anteriormente. Para ello, se partirá de un SBRDs con unas variables difusas prefijadas, calculadas a partir de una distribución equifrecuencial, utilizando 5 conjuntos difusos. En el último paso, con las reglas candidatas generadas, se estimará el consecuente de todas ellas mediante mínimos cuadrados. La comparación entre los dos enfoques se hará en relación a la capacidad de predicción, medido como la raíz cuadrada del error cuadrático medio (RECM), y en cuanto



a la complejidad del sistema generado, tanto en número de reglas candidatas generadas como en tiempo consumido (en segundos). Respecto al hardware utilizado, la máquina donde se ejecutaron los experimentos consta de un procesador Intel Xeon E5450 a 3.00GHz y 32GB de memoria RAM.

Para la comparativa se han utilizado 7 datasets del repositorio KEEL<sup>2</sup>, con número de variables que va desde 16 hasta 85. En la Tabla I se puede observar, para cada problema, su número de variables e instancias, además del dominio de la variable de salida. Con respecto a la parametrización de los algoritmos de generación de reglas candidatas, se ha fijado el parámetro  $min\_soporte = 0,05$  en ambos casos,  $k_t = 20$  para la fase *prescreening* del algoritmo descrito en [5] (como recomiendan los autores), y  $min\_quality\_improvement = 0,5$  en nuestra propuesta. Finalmente, en problemas de alta dimensionalidad hemos notado que el algoritmo tendía a incluir un elevado número de antecedentes por regla. Este hecho disminuye enormemente la interpretabilidad del sistema. Para evitar este problema, hemos usado un umbral variable para el mínimo soporte, siendo éste  $min\_support_i = min\_support \cdot \sqrt{depth\_level}$ , siendo  $depth\_level$  la profundidad del nodo en el árbol de búsqueda.

Tabla I  
CARACTERÍSTICAS DE LOS PROBLEMAS UTILIZADOS EN LA EXPERIMENTACIÓN

problema	#variables	#instancias	rango Y
house	16	22784	[0, 500001]
elevators	18	16599	[0.012, 0.078]
compactiv	21	8192	[0.0, 99.0]
pole	26	14998	[0.0, 100.0]
puma32h	32	8192	[-0.086661, 0.089805]
ailérons	40	13750	[-0.0036, 0.0]
tic	85	9822	[0, 1]

En la Tabla II se muestran los errores de predicción (RECM tanto para entrenamiento como para test) y el tiempo de aprendizaje en segundos. En la Tabla III se muestra la complejidad de los modelos generados por ambos algoritmos, mostrando el número medio de reglas candidatas ( $|reglas|$ ) y el número medio de antecedentes por regla ( $|#ant|$ ).

Como puede observarse, en cuanto a capacidad de predicción, nuestra propuesta es mejor para los 7 conjuntos de datos, tanto en error de entrenamiento como de test. Atendiendo a la complejidad de los sistemas de reglas generados, observamos que el método propuesto produce siempre conjuntos con un mayor número de reglas, aunque en 4 de los 7 problemas éstas tienen un menor número medio de antecedentes. Analizando conjuntamente esta información podemos concluir que, aunque nuestra propuesta siempre mejora en términos de error de entrenamiento, puede deberse en parte al aumento en el número de reglas candidatas, ya que la técnica de mínimos cuadrados tiende a sobreajustar el conjunto de entrenamiento. No obstante, también observamos una mejora en cuanto al

Tabla II  
RAÍZ DEL ERROR CUADRÁTICO MEDIO DE ENTRENAMIENTO Y DE TEST, Y TIEMPO DE EJECUCIÓN PARA EL ALGORITMO DE GENERACIÓN BASADO EN DOS FASES. EN EL CASO DE LOS PROBLEMAS ELEVATORS, PUMA32H Y AILERONS SE MUESTRA EL ERROR  $\cdot 10^3$ .

Generación en dos fases			
problema	RECM (entr.)	RECM (test)	Tiempo (s)
house	37292.24	37454.70	220.73
elevators	5.41	5.47	447.97
compactiv	10.92	11.04	183.58
pole	32.16	32.22	411.43
puma32h	24.46	24.59	419.07
ailérons	0.29	0.29	5204.02
tic	0.23	0.24	16784.83
Generación en una fase			
problema	RECM (entr.)	RECM (test)	Tiempo (s)
house	<b>35506.00</b>	<b>36083.98</b>	<b>96.67</b>
elevators	<b>3.71</b>	<b>3.82</b>	<b>113.29</b>
compactiv	<b>3.07</b>	<b>3.36</b>	<b>103.88</b>
pole	<b>17.07</b>	<b>17.18</b>	<b>31.66</b>
puma32h	<b>20.00</b>	<b>20.42</b>	<b>63.39</b>
ailérons	<b>0.18</b>	<b>0.19</b>	<b>719.26</b>
tic	<b>0.22</b>	<b>0.23</b>	<b>313.71</b>

Tabla III  
NÚMERO DE REGLAS, REGLAS CANDIDATAS Y NÚMERO MEDIO DE ANTECEDENTES POR REGLA

problem	Generación en dos fases		Generación en una fase	
	$ reglas $	$ #ant $	$ reglas $	$ #ant $
house	<b>76.60</b>	<b>1.39</b>	188.90	1.66
elevators	<b>68.10</b>	1.82	292.07	<b>1.81</b>
compactiv	<b>66.97</b>	<b>1.35</b>	446.37	1.88
pole	<b>42.97</b>	1.48	78.80	<b>1.17</b>
puma32h	<b>53.27</b>	<b>1.03</b>	207.00	1.23
ailérons	<b>46.60</b>	1.91	906.83	<b>1.89</b>
tic	<b>38.70</b>	2.26	384.47	<b>1.42</b>

error de test, lo que nos lleva a concluir que, además, la calidad de las reglas candidatas es similar e incluso mejor.

Respecto al esfuerzo computacional, podemos ver una clara diferencia en cuanto a los tiempos de ejecución. En la Tabla II se aprecia una diferencia que puede alcanzar varios órdenes de magnitud. Este resultado es muy importante, y demuestra la capacidad de encontrar un conjunto de reglas candidatas de calidad de una forma muchísimo más eficiente.

Por último, en la Figura 4 podemos ver una comparativa de los tiempos aplicando una transformación logarítmica ( $f(x) = \log_{10}(1 + x)$ ), para poder visualizar las diferencias de tiempo para todos los problemas a la vez. Como se puede observar, las diferencias de tiempos se hacen más notables conforme aumenta el número de variables del problema.

## V. CONCLUSIÓN

En este trabajo se ha propuesto un algoritmo para la generación de reglas candidatas tipo TSK-0 en problemas de regresión. Para ello, se ha tomado como punto de partida el trabajo realizado en [5], el cual propone un algoritmo dividido en dos fases. La primera de ellas, apoyada en el principio Apriori para generar un conjunto de reglas general de forma eficientemente. Para ello, el proceso es guiado por la métrica de soporte de cada regla candidata. En una segunda fase, se aplica un filtrado enfocado a evitar la redundancia de reglas

<sup>2</sup>www.keel.es/

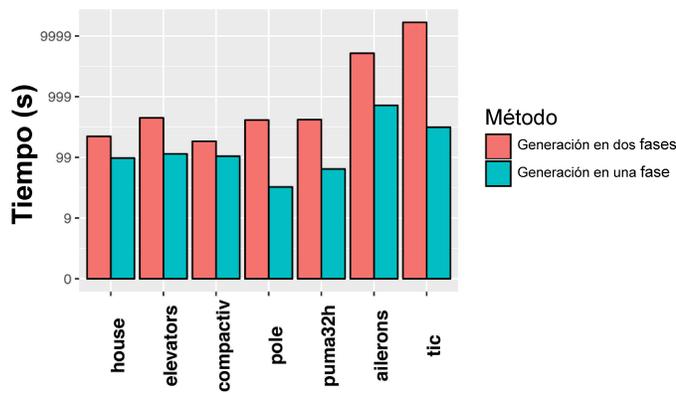


Figura 4. Comparativa de tiempos para ambos métodos en escala logarítmica

candidatas. Además, este proceso es guiado por una métrica de calidad individual de las reglas, centrada en evaluar la calidad predictiva de cada una de ellas.

Existen principalmente dos problemas en la propuesta anterior. Por un lado, se genera un elevado número de reglas candidatas en la primera fase. Por otro lado, la segunda fase requiere un gran esfuerzo computacional al aplicar una selección de reglas candidatas (generadas por la primera fase) de forma iterativa. Estos problemas hacen que su uso sea ineficiente y, en ocasiones, impracticable en problemas de alta dimensionalidad. Nuestra propuesta se centra en la unificación de las dos fases, diseñando una métrica de calidad de predicción individual monótona, capaz de ser combinada con el soporte y que sirva como guía en el proceso de construcción del árbol de búsqueda del que se extraen las reglas candidatas.

Los resultados demuestran una calidad similar o incluso superior en cuanto a la capacidad de predicción del conjunto de reglas candidatas, y una grandísima mejora en cuanto a la eficiencia. En trabajos futuros pretendemos ampliar la experimentación, utilizando un mayor conjunto de problemas, a la vez que validando el conjunto de reglas candidatas con varios algoritmos de búsqueda para la selección de las reglas que formarán el sistema de reglas. En este sentido, [13] y [14] se centran en utilizar algoritmos de búsqueda local, los cuales permiten realizar esta búsqueda eficientemente explotando la localidad espacial de las etiquetas difusas, lo que los hace adecuados para problemas de alta dimensionalidad.

#### AGRADECIMIENTOS

Este artículo ha sido parcialmente financiado por fondos FEDER y la Agencia Estatal de Investigación (AEI/MINECO) mediante el proyecto TIN2016-77902-C3-1-P, y por la Junta de Comunidades de Castilla-La Mancha mediante el proyecto SBPLY/17/18050/000493. Javier Cózar también está financiado por el MECD mediante la beca FPU12/05102.

#### REFERENCIAS

[1] L. Zadeh, "Outline of a new approach to the analysis of complex systems and decision processes," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 3, no. 1, pp. 28–44, 1973.

[2] E. Mamdani and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *International Journal of Man-Machine Studies*, vol. 7, pp. 1–13, 1975.

[3] E. Mamdani, "Applications of fuzzy algorithm for control a simple dynamic plant," pp. 1585–1588, 1974.

[4] J. Alcalá-Fdez, R. Alcalá, and F. Herrera, "A fuzzy association rule-based classification model for high-dimensional problems with genetic rule selection and lateral tuning," *Fuzzy Systems, IEEE Transactions*, vol. 19, no. 5, pp. 857–872, 2011.

[5] J. Cózar, L. delaOssa, and J. A. Gámez, "TSK-0 fuzzy rule-based systems for high-dimensional problems using the apriori principle for rule generation," *Rough Sets and Current Trends in Computing*, vol. 8536, pp. 270–279, 2014.

[6] R. Agrawal, T. Imieliński, and A. Swami, "Mining association rules between sets of items in large databases," *SIGMOD Rec.*, vol. 22, no. 2, pp. 207–216, Jun. 1993.

[7] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications for modeling and control," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 15, no. 1, pp. 116–132, 1985.

[8] L. Zadeh, "The concept of a linguistic variable and its application to approximate reasoning," *Information Science*, vol. 8, pp. 199–249, 1975.

[9] L. Wang and J. Mendel, "Generating fuzzy rules by learning from examples," *Systems, Man and Cybernetics, IEEE Transactions*, vol. 22, no. 6, pp. 1414–1427, 1992.

[10] O. Cerdón and F. Herrera, "A proposal for improving the accuracy of linguistic modeling," *Fuzzy Systems, IEEE Transactions*, vol. 8, no. 3, pp. 335–344, 2000.

[11] K. Nozaki, H. Ishibuchi, and H. Tanaka, "A simple but powerful heuristic method for generating fuzzy rules from numerical data," *Fuzzy Sets and Systems*, vol. 86, pp. 251–270, 1997.

[12] V. C. Klema and A. J. Laub, "The singular value decomposition: Its computation and some applications," *Automatic Control, IEEE Transactions*, vol. 25, no. 2, pp. 164–176, 1980.

[13] J. Cózar, L. delaOssa, and J. A. Gámez, "Learning TSK-0 linguistic fuzzy rules by means of local search algorithms," *Applied Soft Computing*, vol. 21, no. 0, pp. 57–71, 2014.

[14] J. Cózar, L. delaOssa, and J. A. Gámez, "Learning compact zero-order tsk fuzzy rule-based systems for high-dimensional problems using an apriori + local search approach," *Information Sciences*, vol. 433 - 434, pp. 1 – 16, 2017.



# Un modelo difuso lingüístico adaptativo para regresión con selección de reglas en Big Data

Antonio Ángel Márquez      Ana María Roldán  
 Departamento de Tecnologías de la Información  
 Universidad de Huelva  
 Huelva – España  
 amarquez, amroldan@dti.uhu.es

Francisco Alfredo Márquez      Antonio Peregrín  
 C.E. Avanzados en Física, Matemáticas y Computación  
 Universidad de Huelva  
 Huelva – España  
 alfredo.marquez, peregrin@dti.uhu.es

**Abstract**—En el diseño de sistemas basados en reglas difusas para regresión, son bien conocidos los modelos que permiten obtener la base de reglas a partir de conjuntos de datos por cubrimiento, así como los que posteriormente permiten mejorar la precisión del sistema empleando, por ejemplo, un ajuste del operador de defuzzificación adaptativo que, además, permita obtener un conjunto de reglas más compacto y con mejor nivel de cooperación. En este trabajo se lleva a cabo este proceso en entornos de *Big Data*, es decir, adaptando los algoritmos a esta tecnología para que se puedan utilizar partiendo de conjuntos de ejemplos que no serían manejables sin disponer de una infraestructura escalable.

**Keywords**—regresión difusa; bases de reglas; defuzzificación adaptativa; *Big Data*; *MapReduce*.

## I. INTRODUCCIÓN

En el área de los *Sistemas Basados en Reglas Difusas* en general, y para modelado y control en particular, existe una considerable cantidad de trabajos que emplean algoritmos evolutivos para aprender y/o ajustar elementos del sistema, que van por ejemplo desde los de la Base de Conocimiento (BC) como el aprendizaje de la Base de Reglas (BR), o ajuste de la Base de Datos (BD), hasta incluso los operadores, como en [1], [2]. A todo este ámbito se le llamó el de los *Sistemas Difusos Evolutivos* [3], [4], [5], y en él se han desarrollado pues, gran cantidad de recursos muy útiles desde hace más de dos décadas. Estos algoritmos utilizan conjuntos de ejemplos desde los que aprender o evaluar los distintos citados elementos.

La posibilidad de emplear conjuntos de ejemplos más grandes con algunas de estas técnicas ha sido tratada a veces por distintos autores: cuando los conjuntos de ejemplos son muy grandes, las técnicas utilizadas pueden necesitar modificaciones o re-implementaciones para que sigan siendo aptas. Tradicionalmente, las mejoras en este sentido [5] se han orientado a la reducción de datos, al uso de aproximaciones o estimaciones, a la introducción de heurísticas en los algoritmos para mejorar su eficiencia, y en algunos pocos casos, al uso de computación distribuida. Sin embargo, es con la llegada de los recursos para afrontar el tratamiento de grandes conjuntos de datos en entornos de *Big Data*, cuando se dispone de herramientas para hacer verdaderamente escalables algunas de estas técnicas tradicionales.

Este trabajo trata precisamente del uso de recursos computacionales distribuidos del ámbito del *Big Data*, para emplear una técnica tradicional, como es el ajuste de la defuzzificación adaptativa en regresión y control difusos, cuando el conjunto de ejemplos es grande, o simplemente cuando el aprovechamiento de estos recursos nos permite realizar el mismo trabajo en tiempos menores, lo cual por ejemplo con el uso de algoritmos evolutivos, puede ser una interesante mejora.

## II. CONOCIMIENTOS PREVIOS

En esta Sección se van a repasar brevemente dos elementos que empleamos en nuestra propuesta: la defuzzificación adaptativa, y la tecnología *MapReduce*.

### A. Defuzzificación Adaptativa Evolutiva

La defuzzificación adaptativa es un recurso tradicional y bien conocido que permite adaptar el comportamiento del mecanismo de obtención de una salida específica desde la aportación de cada regla disparada en la fase de inferencia en regresión difusa, consiguiendo mejorar la precisión del modelo resultante, pues cada regla participa en dicho proceso de una forma específica y diferente al resto [1],[2].

Es posible encontrar múltiples propuestas en la literatura para conseguir regular o adaptar el mecanismo de defuzzificación mediante el uso de parámetros. Sin embargo, lo más frecuente suele ser utilizar la expresión (1), dados sus buenos resultados, su sencillez computacional y facilidad de implementación [2],

$$y_0 = \frac{\sum_i^N h_i \cdot \alpha_i \cdot CG_i}{\sum_i^N h_i \cdot \alpha_i}, \quad (1)$$

donde  $h_i$  es el *matching degree* o grado de emparejamiento,  $\alpha_i$  es el parámetro que se aplica con la regla  $i$ -ésima,  $R_i$ , con  $i=1$  hasta  $N$ , y  $CG_i$  es el Centro de Gravedad de la figura obtenida de la inferencia con la regla  $R_i$ . Como se puede ver, se trata de la expresión de un método de defuzzificación que actúa convirtiendo la aportación de cada regla en un número, y posteriormente calculando una media ponderada, es decir, del llamado *Modo-B*. El parámetro  $\alpha_i$  pues, tomando valores en el intervalo  $[0,1]$ , permite a su vez ponderar o reducir el efecto del

grado de emparejamiento,  $h_i$ , como si de un peso,  $w_i$ , se tratase [6].

Para conseguir el ajuste de los  $N$  citados  $\alpha_i$  parámetros, es decir, reducir la diferencia entre la salida del sistema difuso y el conjunto de ejemplos, se podrían emplear diferentes métodos. En este sentido, el uso de algoritmos evolutivos suele ser una buena opción. La codificación empleada en este caso es de tipo real, pues como se ha indicado, el valor de los parámetros  $\alpha_i$  se encuentra entre 0 y 1.

Obsérvese que este mecanismo de ajuste paramétrico no sólo permite que la aportación de cada regla sea regulada sino que a través de él, se consigue mejorar el nivel de cooperación entre las reglas de la BC [1]. Incluso llevado al extremo, la defuzzificación adaptativa puede emplearse como mecanismo de selección y reducción de reglas: si una regla tiene un valor 0 para su parámetro, dicha regla no participa o deja de ser considerada. El hecho de disponer de un mecanismo que permita eliminar reglas es particularmente interesante cuando dichas reglas provienen de un proceso de aprendizaje que no las ha valorado en su conjunto, como suelen ser los métodos basados en cubrimiento de ejemplos, donde cada regla se obtiene con criterios de calidad individual.

Cabe mencionar también en este sentido, que en [7] se propone un mecanismo para facilitar la eliminación de reglas con aportación baja, basado en eliminar aquellas reglas cuyo parámetro descende por debajo de cierto umbral (es decir, no sólo cuando el valor es exactamente 0). En el citado trabajo, también se elimina el parámetro de las reglas cuyo valor está cercano a 1, suponiendo por tanto una reducción de la carga computacional y reduciendo la complejidad de la BC, pues se reduce el número de reglas, y el número de reglas con parámetro asociado.

### B. Tecnologías para Big Data

En los últimos años se han desarrollado un conjunto de tecnologías para el almacenamiento, gestión y tratamiento de grandes conjuntos de datos de forma distribuida y escalable. A estas tecnologías se les suele llamar genéricamente, tecnologías para *Big Data* [8] y los tres pilares en los que se apoyan estas tecnologías actualmente son:

- Sistemas de archivos distribuidos, donde los grandes archivos de datos se almacenan divididos entre varios servidores, tales como el popular *Apache Hadoop Distributed File System* (HDFS) [10].
- Paradigmas de programación tales como *MapReduce* [11] o *Pregel* [12], que permiten implementar procesos de computación en *clusters* de computadoras.
- Entornos para *clusters* de computación como *Apache Hadoop* [10] o *Apache Spark* [13] que nos permiten organizar y gestionar grupos de computadoras tanto como sistemas de almacenamiento (a través de sistemas de archivos distribuidos) como estructuras de procesamiento de datos (implementando modelos de programación distribuida) eficientemente.

El paradigma de programación *MapReduce* lo introdujo Google en 2004 [11]. Una de sus mejor conocidas y empleadas

implementaciones en código abierto es *Apache Hadoop*, la cual, implementa características como el almacenamiento y procesamiento escalables, los cuales se pueden usar de forma relativamente sencilla, tienen elevada tolerancia a fallos, alta disponibilidad, redundancia de datos automática, etc. A nivel de procesamiento, *Hadoop* está pensado para emplearse procesando datos en una sola pasada, esto es, no es eficiente implementando múltiples pasadas de procesamiento sobre los datos, así como tampoco está pensando para procesamiento de datos interactivamente. *Apache Spark* [13] sin embargo, sí resuelve estas situaciones.

*Apache Spark* es igualmente un entorno para la programación distribuida de código abierto, ideado como un paso adelante en cuanto a flexibilidad y eficiencia. No sólo permite utilizar el modelo de computación *MapReduce*, si bien considerablemente más rápido [13] que *Hadoop*, sino también *Pregel* [12] y el suyo propio. Pero una de las ventajas más interesantes de *Spark* es que permite implementar de forma eficiente el procesamiento de datos iterativo o multi-pasada, debido al uso particular de la memoria RAM que implementa, a través de una abstracción de memoria distribuida conocida como RDD (*Resilient Distributed Dataset*) [13], que le permite reducir el acceso a disco intermedio mejorándose así dramáticamente su rendimiento. Los RDDs son conjuntos de datos que se ubican físicamente troceados entre distintos servidores del *cluster*, y que pueden ser procesados en paralelo. Los programadores emplean estos RDDs a través de transformaciones, que los procesan produciendo otros RDDs, o bien mediante acciones, que les aplican un procesamiento que ofrece como salida un valor o cálculo. La tolerancia a fallos se obtiene precisamente gracias a los citados RDDs, ya que estos pueden ser reconstruidos automáticamente si por alguna razón, se perdiesen durante su procesamiento.

Los programas implementados para ser ejecutados en *Spark* se componen de una única aplicación *driver* que se ejecuta en el nodo maestro, y un conjunto de tareas que corren en paralelo en los *ejecutores* sobre los nodos trabajadores del *cluster*, devolviendo sus resultados al *driver*.

Cabe destacar que *Spark* también permite realizar trabajos de computación distribuida de forma interactiva, es decir, instrucción a instrucción desde intérprete de comandos, y que puede utilizar HDFS como sistema de archivos distribuido.

El mecanismo que se propone en este trabajo utiliza *Spark* y el modelo de computación *MapReduce*.

### III. MODELO CON POST-PROCESAMIENTO PARA EL AJUSTE DE LA DEFUZZIFICACIÓN Y SELECCIÓN DE REGLAS

En esta Sección se propone un modelo distribuido escalable implementado en el entorno *Spark*, que consta de dos etapas: en una primera etapa se obtiene la BR basándonos en la versión *MapReduce* de un método archiconocido para la obtención de reglas por cubrimiento de ejemplos, y una segunda en la que también de modo distribuido y escalable, se ajustarán mediante un algoritmo evolutivo los parámetros de la defuzzificación, empleando umbrales para seleccionar el subconjunto de reglas que mejor cooperan.



### A. Obtención Escalable de la BR desde Conjuntos de Datos

El llamado “Método de Wang y Mendel” dirigido por datos [14] (WM en adelante) es un algoritmo extraordinariamente conocido para obtener BRs partiendo de un conjunto de ejemplos. En un trabajo previo [15], propusimos una versión adaptada del mismo basada en el uso de *MapReduce*, que llamamos *WM-Escalable*. Los resultados que produce son idénticos a los que produciría la metodología secuencial original de WM, y resumimos a continuación:

Los conjuntos de datos de ejemplos son troceados y repartidos entre los servidores del *cluster* para ser procesados de forma separada. En este caso, para obtener la BR usando el método de WM, sólo se necesita un esquema de una sola pasada, es decir, una sola fase *Map* y a continuación una fase *Reduce*. Los elementos son:

- Programa *Driver*: El programa *driver* ejecutado en el nodo maestro, en primer lugar, crea la BD utilizando un número predefinido de funciones de pertenencia distribuidas uniformemente en el universo de discurso de cada variable. En segundo lugar, el conjunto de entrenamiento se divide en  $n$  particiones disjuntas con el mismo número de instancias, y cada una de estas particiones se distribuye entre los nodos trabajadores del *cluster* junto con la citada BD.
- Función *Map*: Las funciones *Map* consisten en la aplicación de la metodología original de WM por parte de los procesos *ejecutores* sobre nodos trabajadores, cada uno en su subconjunto de ejemplos, que quedan así cubiertos por alguna de las reglas generadas. El método de WM consigue esto en primer lugar cubriendo cada ejemplo con una regla difusa que utiliza las etiquetas que tienen el mayor grado de pertenencia para cada variable, y además le asigna un valor que es el grado de emparejamiento de esa regla con ese ejemplo, el cual será empleado en una segunda fase para reducir el conjunto de reglas, es decir, para no tener tantas reglas como ejemplos sino sólo un subconjunto combinado de las reglas más representativas. La salida de estos procesos *Map* se produce en términos de pares *clave-valor* (siendo recibida por el *driver*), donde la **clave** son las *etiquetas de los antecedentes de las reglas halladas*, y el **valor** asociado son *el consecuente de las reglas encontradas, junto con el grado de emparejamiento de las reglas*.
- Función *Reduce*: La tarea de las funciones *Reduce* en este esquema es la de recibir las distintas reglas producidas por las funciones *Map*, ( $RB_i$ ), y agruparlas para construir la BR definitiva. Para ello, debe eliminar las reglas repetidas, es decir, las que tienen los mismos antecedentes y el mismo consecuente, y resolver las reglas contradictorias, es decir, las que con los mismos antecedentes tienen distinto consecuente, lo cual se lleva a cabo eligiendo la que viene acompañada por el mayor grado de emparejamiento. En términos del diseño *clave-valor* de *MapReduce*, la función *Reduce* recibe una lista de valores intermedios compuesta por pares agrupados por claves (**clave**: *etiquetas de la parte antecedente de una regla*, y **lista de valores**: *consecuentes para esa parte antecedente de una regla*

y sus grados de emparejamiento). La BR final está pues compuesta por el conjunto de reglas obtenidas por las funciones *Reduce*.

### B. Aprendizaje Escalable Evolutivo de los parámetros para la Defuzzificación Adaptativa con Selección de Reglas

En esta Subsección se describe la parte original de este trabajo, donde se propone un método evolutivo para aprender o ajustar los valores de la defuzzificación adaptativa utilizando conjuntos de ejemplos muy grandes de forma eficiente, y especialmente apropiada al uso de BRs aprendidas mediante métodos de cubrimiento de ejemplos, ya que incorpora un mecanismo de selección de reglas, tal como se introdujo previamente en la Sección II, al que llamaremos *Defuzzificación Adaptativa Evolutiva con Selección de Reglas Escalable* (abreviado como *E-DAESR*). La originalidad en este trabajo está, no en el diseño evolutivo de defuzzificación adaptativa [2], sino en la escalabilidad de la propuesta. No repetiremos pues los detalles ya descritos previamente sino que nos centraremos en el diseño *MapReduce* del mecanismo, el cual, es equivalente exactamente al modelo secuencial original [2].

#### 1) Algoritmo Evolutivo

Previamente, se va a describir el esquema evolutivo empleado, ya que de su detalle depende la posterior descripción del mecanismo para la escalabilidad de la propuesta. Se basa en el modelo CHC [16]. Sus componentes son:

#### Esquema de codificación y población inicial

El esquema de codificación empleado es el de [1], que consiste en un cromosoma de tipo real con  $N$  genes,  $\alpha_i$ , que representan cada uno al parámetro asociado a cada regla  $R_i$  de la RB, y cada uno de ellos toma valores en el intervalo  $[0,1]$ .

$$C = (\alpha_1, \dots, \alpha_N) \mid \alpha_i \in \{0, 1\}$$

La población inicial se inicializa con todos los genes de cada cromosoma elegidos aleatoriamente en el intervalo anteriormente citado, excepto los de uno, cuyos genes se fijan a 1, lo que equivale al método estándar conocido como *CG ponderado por el grado de emparejamiento*.

#### Evaluación

La evaluación de los cromosomas consiste en tasar el modelo difuso con los parámetros de ese cromosoma. Dado que lo que se pretende resolver con esta propuesta es precisamente el uso de conjuntos de ejemplos muy grandes, este proceso es el que se realiza de forma distribuida por los *ejecutores* de *Spark*, como se describirá posteriormente. Para maximizar la precisión, minimizamos el Error Cuadrático Medio (MSE) cuya expresión es (2), donde  $S [i]$  denota a los diferentes modelos difusos probados. Para ello, se utiliza un conjunto de evaluación compuesto por  $P$  pares de datos numéricos  $Z_k = (x_k, y_k)$ ,  $k=1, \dots, P$ , siendo  $x_k$  los valores de las variables de entrada, e  $y_k$  los valores correspondientes de las variables de salida.

$$\text{MSE} (S [i]) = \frac{1}{2} \frac{\sum_{k=1}^N (y_k - S [i](x_k))^2}{N} \quad (2)$$

Destacamos que, para llevar a cabo la selección de reglas mediante umbrales como en [7] se tiene en cuenta sólo y

simplemente cuando se evalúa el sistema difuso, es decir, los valores de los parámetros en los cromosomas se mantienen, pero por debajo de cierto umbral (se ha utilizado el valor 0.1), no se usa la regla, al igual que por encima de cierto umbral (se ha usado 0.9), se considera que el peso es 1.

*Operador de cruce y criterio de reorganización*

Empleamos el operador de cruce BLX- $\alpha$  [17], con  $\alpha = 0.5$ , y umbral inicial  $L/4$ . Cuando el umbral es menor que 0, se reorganiza, construyéndose la población aleatoriamente excepto para el mejor de los padres de la población anterior.

2) *Esquema MapReduce para la Defuzz. Adaptativa*

A continuación se describe el diseño MapReduce realizado para construir el modelo E-DAESR, ilustrado en la Figura 1.

- Programa *Driver*: El programa *driver*, ejecutado en el nodo maestro, es el que se ocupa de llevar a cabo la mayor parte del algoritmo evolutivo que aprende los parámetros de la defuzzificación asociados a cada una de las reglas  $R_i$  de la BR, cediendo el proceso más pesado, la evaluación con el conjunto de ejemplos, a la función *Map*, que se ejecuta de forma distribuida en el *cluster* en cada iteración del algoritmo evolutivo. El programa *driver* al inicio, divide y distribuye el conjunto de ejemplos en tantas unidades diferentes como elementos de procesamiento tenga el *cluster*. Asimismo, también distribuye una copia de la BC y la población completa de cromosomas a evaluar.
- Función *Map*: La evaluación de la población de cromosomas del algoritmo evolutivo es llevada a cabo por parte de los procesos *ejecutores* dentro de los nodos *trabajadores* del *cluster*, con su fracción del conjunto de ejemplos, obteniéndose por tanto el MSE para ese subconjunto. La función *Map* produce una lista de pares *clave-valor* intermedios que son devueltos al proceso *driver* tras su ejecución, de modo que la **clave** son *los cromosomas (parámetros asociados con cada*

*regla*) y el **valor** es *el valor de evaluación (MSE) obtenido por la BR con los parámetros para la defuzzificación que lleva cada cromosoma.*

- Función *Reduce*: También son realizadas por los *ejecutores*: una o varias funciones *Reduce* reciben los resultados de los *Maps* y los combinan para tener el resultado completo de la evaluación para cada cromosoma. En términos de pares *clave-valor*, las funciones *Reduce* reciben una lista de valores intermedios agregados por la clave, de modo que la **clave** es *el cromosoma (los valores de los parámetros para cada regla)*, y como **lista de valores**, una lista de *la evaluación de cada cromosoma en cada partición de datos*, y ofrecen una lista de cromosomas con su valor de evaluación con el conjunto de ejemplos completo. La evaluación obtenida por todos los cromosomas es enviada al programa *driver* para que continúe el proceso evolutivo.

IV. ESTUDIO EXPERIMENTAL

En esta Sección se describe el estudio experimental llevado a cabo para comprobar el funcionamiento del modelo propuesto, tanto en cuanto a precisión como a escalabilidad.

En primer lugar, se hará referencia a los conjuntos de datos empleados, posteriormente se describirá la configuración seleccionada para el estudio experimental y los test estadísticos, y finalmente se mostrarán los resultados y su análisis, así como el estudio de escalabilidad.

Se van a utilizar 10 problemas con diferente nivel de dificultad, por ejemplo, con distinto número de variables e instancias, etc. Proviene del repositorio KEEL [18], y se muestran en la Tabla I junto con sus características.

A. Configuración de los Experimentos

En cuanto la configuración de los experimentos, se ha utilizado validación cruzada de orden 5, es decir, se han hecho 5

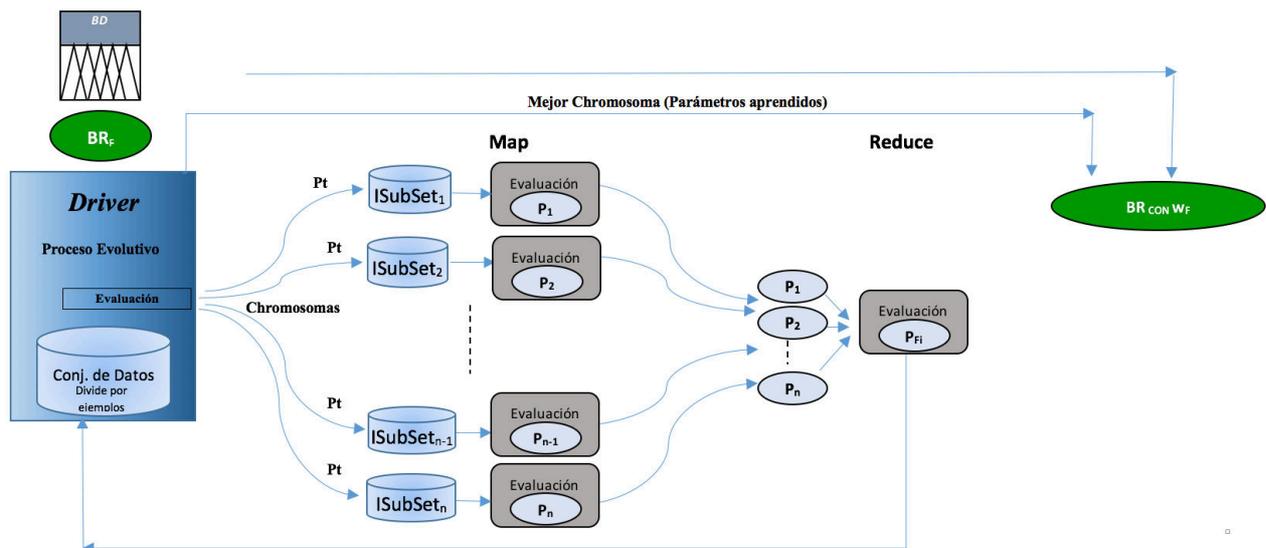


Fig. 1. Esquema de E-DAESR

TABLE I. CONJUNTOS DE DATOS UTILIZADOS, DISPONIBLES EN EL REPOSITORIO KEEL (HTTP://SCI2S.UGR.ES/KEEL/DATASETS.PHP)

Problem	Abbreviation	Instances	Variables
Delta-elv	DELV	9517	6
California	CAL	20640	8
Mv	MV	40768	10
House	HOU	22768	16
Elevators	ELV	16599	18
Compactiv	CA	8192	21
Pole	POL	14998	26
Puma32	PUM	8192	32
Airelons	AIL	13750	40
Tic	TIC	9822	85

particiones aleatorias de los conjuntos de datos, cada una con un 20%, y la combinación de 4 de ellos, es decir, el 80%, se han usado como conjunto de entrenamiento, mientras que los restantes son el conjunto de prueba.

En cuanto a los sistemas difusos, las BCs utilizadas emplean 3 etiquetas lingüísticas triangulares en todos los casos. El operador utilizado como conjunción y como inferencia para ambos casos es la t-norma del mínimo. El método de defuzzificación empleado para la obtención de la BR, por tanto, no adaptativo, es el *CG ponderado por el grado de emparejamiento*, mientras que el adaptativo de la propuesta es el de la expresión (1) (los cuales son equivalentes cuando el parámetro de cada regla tiene el valor 1).

En cuanto al algoritmo evolutivo, cuyo modelo se ha descrito en la Sección III, se ha ejecutado 30 veces: 6 semillas para el generador de números aleatorios, y 5 particiones para cada conjunto de datos o problema. La longitud de población utilizada es 61 cromosomas; la probabilidad de cruce se ha fijado a 1, y el número máximo de evaluaciones configurado ha sido 100000.

Para realizar la experimentación hemos utilizado un *cluster virtual* formado por 17 servidores con 4 núcleos y 8 GB de RAM cada uno. Uno de ellos se ocupa de ejecutar exclusivamente el programa *driver*, es decir, actúa de nodo maestro, y los 16 restantes como trabajadores para los procesos *ejecutores*.

Para realizar los estudios de escalabilidad se ha optado por hacer las dos siguientes configuraciones del *cluster*:

- Una configuración simple, con solo 2 núcleos, para poder medir el tiempo necesario por un servidor básico.
- Una configuración en modo *cluster* con el total de los 16 servidores, tanto con 16 como con 32 núcleos.

Se han realizado test estadísticos [19] [20], para comparar los resultados, empleando un *signed-rank test* de Wilcoxon.

### B. Resultados Obtenidos y Análisis

La Tabla II muestra los resultados obtenidos por el modelo propuesto con defuzzificación adaptativa escalable, *E-DAESR*, en comparación con el modelo que no la utiliza, ambos con las mismas BRs obtenidas por el método de *WM-Escalable* [15]. En particular, para cada modelo, se muestra el número de reglas obtenidas, y los MSE en entrenamiento y prueba. Observando esta información, analizamos que:

- El número de reglas que se obtienen en general empleando el método propuesto *E-DAESR* es considerablemente inferior al que se obtiene empleando el método de cubrimiento (*WM-Escalable*), por tanto, se consiguen modelos más compactos. La excepción son precisamente los problemas que por su complejidad, presentan mayor número de reglas: quizás el espacio de búsqueda es “demasiado grande” para la configuración del algoritmo evolutivo básica empleada, por lo que habría que probar otros ajustes que hiciesen la búsqueda más efectiva.
- La precisión en general es de nuevo considerablemente mejor en el modelo propuesto. Sin embargo, se observa que en algunos problemas dicha reducción es escasa, coincidiendo con los problemas que en el párrafo anterior destacábamos con una inferior reducción en el número de reglas: se hace conveniente probar configuraciones diferentes.

Las Tablas III y IV muestran los resultados de los test de Wilcoxon empleados para confirmar que la reducción del número de reglas y la mejora en la precisión son significativas.

TABLA II. WM-ESCALABLE VS. E-DAESR (LOS VALORES DE MSE EN ESTA TABLA DEBEN MULTIPLICARSE POR 10<sup>-6</sup>, 10<sup>-8</sup>, 10<sup>9</sup>.10<sup>-6</sup>, 10<sup>-8</sup> Y 10<sup>-4</sup> PARA DELV, CAL, HOU, ELV, AIL Y TIC RESPECTIVAMENTE).

Datasets	WM-Escalable			E-DAESR		
	#R	MSE <sub>tra</sub>	MSE <sub>est</sub>	#R	MSE <sub>tra</sub>	MSE <sub>est</sub>
DELV	129.4	2.372718	2.375347	<b>47.1</b>	1.602017	<b>1.628900</b>
CAL	123.4	5.319310	5.335769	<b>41.2</b>	3.215826	<b>3.225589</b>
MV	3677.8	13.795066	13.998455	<b>3126.4</b>	6.281729	<b>6.669283</b>
HOU	756.4	16.445739	16.724978	<b>281.8</b>	9.706077	<b>10.455755</b>
ELV	508.8	16.446985	16.494120	<b>108.3</b>	9.829008	<b>10.052612</b>
CA	424.8	40.383642	40.956170	<b>139.0</b>	5.345838	<b>6.636041</b>
POL	1087.0	399.773700	401.554456	<b>559.1</b>	174.488994	<b>181.557838</b>
PUM	6553.6	0.000250	0.000589	<b>6500.1</b>	0.000242	<b>0.000587</b>
AIL	1072.0	3.450536	3.496296	<b>470.3</b>	1.893806	<b>2.004145</b>
TIC	5802.4	151.609692	500.967975	<b>5707.9</b>	126.557568	<b>499.817874</b>

TABLA III. WILCOXON TEST PARA COMPARAR LA PRECISIÓN DEL MODELO WM-ESCALABLE CON EL MODELO E-DAESR. (R+ SE CORRESPONDE CON LA SUMA DE LOS RANKINGS PARA EL E-DAESR Y R- AL WM-ESCALABLE)

Comparación	R+	R-	p-value
E-DAESR vs. WM-Escalable	0	55	0.0019532

TABLA IV. WILCOXON TEST PARA COMPARAR EL #R DEL MODELO WM-ESCALABLE CON EL DEL MODELO E-DAESR. (R+ SE CORRESPONDE CON LA SUMA DE LOS RANKINGS PARA EL E-DAESR Y R- AL WM-ESCALABLE)

Comparación	R+	R-	p-value
E-DAESR vs. WM-Escalable	0	55	0.0019532

### C. Escalabilidad

Uno de los elementos más interesantes de emplear un enfoque escalable es precisamente, que escale correctamente, es decir, que aumentando el número de elementos de proceso en el *cluster*, le permita reducir los tiempos de ejecución.

Como se comentó en la descripción del estudio experimental, se ha empleado una configuración en el *cluster* con 2 núcleos como equipo básico, y posteriormente con 16 y 32. Los resultados se muestran en la Figura 2: se observa como un mayor número de elementos de cómputo, se refleja en el

*speed-up* (ganancia del tiempo empleado por 32 y 16 núcleos frente al empleado con sólo 2) si bien no es lineal debido a la carga computacional derivada del *framework*.

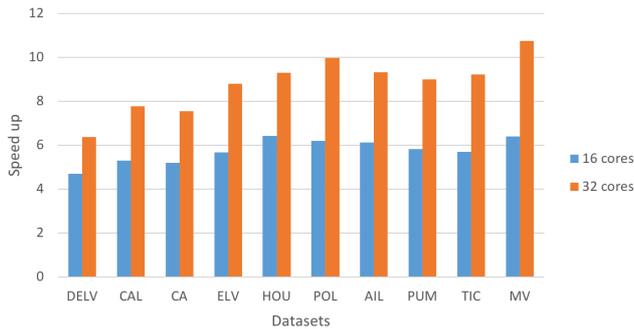


Fig. 2. Escalabilidad obtenida para cada conjunto de datos

### V. CONCLUSIONES

El objetivo planteado en este trabajo era estudiar la adaptación de la metodología del uso de defuzzificación adaptativa con selección de reglas mediante umbrales, a entornos escalables, es decir, la adaptación para su uso en *frameworks* de *Big Data*, y al modelo de computación *MapReduce* implementado en *Apache Spark*.

El resultado de este estudio preliminar es positivo, es decir, se ha conseguido un modelo equivalente (sus resultados son idénticos al modelo secuencial del que proviene) que funciona correctamente, si bien también se observa la necesidad de estudiar algunos casos, con un perfil muy claro (mayor número de reglas) en los que seguramente por falta de una configuración específica del algoritmo evolutivo, la calidad de los resultados no es tan buena, y por tanto, este particular será materia de estudio futuro.

Como se ha visto, en este trabajo se parte del uso del clásico método de WM para aprender las RBs. Este método es muy sencillo e incluso podría decirse que “*muy malo*” en cuanto a precisión y compacidad de la BR aprendida comparativamente con otros métodos, algunos de ellos evolutivos, aparecidos en la literatura durante varias décadas. Sin embargo, queremos hacer notar que lo utilizamos intencionadamente porque el modelo evolutivo empleado posteriormente precisamente permite corregir el principal defecto de las reglas aprendidas siguiendo el método de WM, que es el de la falta de cooperación entre ellas, lo cual es fundamental en regresión difusa. El modelo evolutivo empleado no sólo *gradúa* la contribución de cada regla a través del parámetro o peso, sino que busca la cooperación seleccionando las reglas más apropiadas de las encontradas por el método de WM, produciéndose así una BR final de considerable mayor calidad, más precisa y compacta, sin necesidad de usar un modelo más complejo y de mejor calidad en la primera fase. De cualquier modo, y queda pendiente para un futuro, realizar un estudio sobre cómo afecta la calidad del modelo inicial previo al post-procesamiento evolutivo distribuido propuesto empleando otras alternativas al método de WM, aunque *a priori*, por lo expuesto anteriormente, creemos que será escasa.

### AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Educación y Ciencia dentro del Proyecto TIN2017-89517-P.

### REFERENCIAS

- [1] J. Alcalá-Fdez, F. Herrera, F.A. Márquez, and A. Peregrín, “Increasing fuzzy rules cooperation based on evolutionary adaptive inference systems”, *Int J Intell Syst.* 2007;22(9), pp. 1035–1064.
- [2] F.A. Márquez, A. Peregrín, and F. Herrera, “Cooperative evolutionary learning of linguistic fuzzy rules and parametric aggregation connectors for Mamdani fuzzy system”, *IEEE Trans on Fuzzy Sys.* 2007;15(6), pp.1168–1178.
- [3] F. Herrera, “Genetic fuzzy systems: taxonomy, current research trends and prospects”, *Evol Intell.* 2008;1(1), pp.27–46.
- [4] M. Fazzolari, R. Alcalá, Y. Nojima, H. Ishibuchi, and F. Herrera, “A review of the application of multi-objective evolutionary systems: Current status and further directions”, *IEEE Trans Fuzzy Syst.* 2013; 21(1), pp.45–65.
- [5] A. Fernández, V. López, M.J. del Jesus, and F. Herrera, “Revisiting evolutionary fuzzy systems: Taxonomy, applications, new trends and challenges”, *Knowl Based Syst.* 2015;80, pp.109–121.
- [6] J.S. Cho, and D.J. Park, “Novel fuzzy logic control based on weighting of partially inconsistent rules using neural network”, *J Intel Fuzzy Syst.* 2000;8, pp.99–100.
- [7] A. Márquez, F.A. Márquez, and A. Peregrín, “A Mechanism to Improve the Interpretability of Linguistic Fuzzy Systems with Adaptive Defuzzification based on the use of a Multi-objective Evolutionary Algorithm”, *Int. J. of Comp. Intell. Syst.*, 2012; 5 (2), pp. 297–321.
- [8] D. Laney, “3D data management: controlling data volume, velocity and variety”, *META Group Research Note 6.* 2001; 70.
- [9] A. Fernández, S. del Río, V. López, A. Bawakid, M.J. del Jesus, J.M. Benítez, and F. Herrera, “Big Data with Cloud Computing: an insight on the computing environment, MapReduce, and programming frameworks”, *Wiley Interdiscip. Rev. Data Mining Knowl. Discovery.* 2014;4(5), pp.380–409.
- [10] T. White, “Hadoop: The Definitive Guide”, *O’Reilly Media, Inc.*; 2012.
- [11] J. Dean, and S. Ghemawat, “MapReduce: a flexible data processing tool”, *Commun ACM.* 2010; 53(1), pp.72–77.
- [12] G. Malewicz, M.H. Austern, A.J. Bik, J.C. Dehnert, I. Horn, N. Leiser, and G. Czajkowski, “Pregel: a system for large-scale graph processing”, *In Proceedings of the ACM SIGMOD International Conference on Management of Data.* 2010, pp. 135–146.
- [13] M. Zaharia, R.S. Xin, P. Wendell, T. Das, M. Armbrust, A. Dave, et al., “Apache spark: a unified engine for big data processing”, *Commun ACM.* 2016; 59(11), pp.56–65.
- [14] L. Wang and J. Mendel, “Generating fuzzy rules by learning from examples”, *IEEE Trans Syst, Man, Cybern.* 1992;22(6), pp.1414–1427.
- [15] A.A. Márquez, F.A. Márquez, and A. Peregrín, “A scalable evolutionary linguistic fuzzy system with adaptive defuzzification in big data”, *In Proceedings of the IEEE International Conference on Fuzzy System (FUZZ-IEEE).* 2017; pp.1–6.
- [16] L.J. Eshelman, “The CHC adaptive search algorithm: how to safe search when engaging in nontraditional genetic recombination”, in G.J.E. Rawlings (Ed.), *Foundations of genetic algorithms.* 1991, pp.265–283.
- [17] F. Herrera, M. Lozano, and A. Sánchez, “A taxonomy for the crossover operator for real-coded genetic algorithms: An experimental study”, *Int J Intell Syst.* 2003;18, pp.309–338.
- [18] J. Alcalá-Fdez, L. Sánchez, S. García, M.J. del Jesus, S. Ventura, J. Garrell, et al., “Keel: a software tool to assess evolutionary algorithms for data mining problems”, *Soft Comput.* 2009;13(3), pp.307–318.
- [19] J. Demšar, “Statistical comparisons of classifiers over multiple data sets”, *J Mach Learn Res.* 2006;7, pp.1–30.
- [20] S. García and F. Herrera, “An extension on statistical comparisons of classifiers over multiple data sets for all pairwise comparisons”, *J Mach Learn Res.* 2008;9, pp.2579–2596.

**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 4:  
ADQUISICIÓN  
Y REPRESENTACIÓN  
DEL CONOCIMIENTO







# Estudio sobre la evolución de la relación entre objetos y atributos en una sucesión de contextos L-Fuzzy

Cristina Alcalde

Departamento de Matemática Aplicada  
Universidad del País Vasco - UPV/EHU  
Plaza de Europa 1, 20018 San Sebastian  
Email: c.alcalde@ehu.eus

Ana Burusco

Departamento de Estadística, Informática y Matemáticas  
Instituto de Smart Cities  
Universidad Pública de Navarra  
Campus de Arrosadía, 31006 Pamplona  
Email: burusco@unavarra.es

**Resumen**—En este trabajo avanzamos en el estudio de la evolución de la relación entre los objetos y los atributos en una sucesión de contextos L-Fuzzy. En concreto, analizamos el grado de crecimiento de las tendencias que se estudian mediante las matrices *Trend* y *Persistent*. Para hacerlo, daremos unas nuevas definiciones de niveles *Trend* y *Persistent* con el fin de priorizar los conceptos formales que se obtienen de las matrices *Trend* y *Persistent*. Estos niveles *Trend* y *Persistent* nos permitirán también comparar los distintos objetos y atributos analizando cuáles han sido los que más han evolucionado positivamente a lo largo del tiempo.

Finalmente, ilustraremos nuestros resultados con un ejemplo.

## I. INTRODUCCIÓN

El Análisis de Conceptos L-Fuzzy ([2], [7], [10], [11], [15], [19], [24]) es una herramienta matemática para el análisis y la representación del conocimiento conceptual. Esta teoría utiliza los conceptos L-fuzzy para extraer información de un contexto L-fuzzy. Recordemos que un contexto L-fuzzy es una tupla  $(L, X, Y, R)$ , donde  $L$  es un retículo completo,  $X$  e  $Y$  son conjuntos de objetos y atributos, y  $R \in L^{X \times Y}$  es una relación L-fuzzy entre los objetos y los atributos. Podemos entender el Análisis de Conceptos L-fuzzy como una extensión del Análisis de Conceptos Formales de Wille ([18], [29]).

En algunos casos, podemos tener varias relaciones entre el conjunto de objetos  $X$  y el de atributos  $Y$ . Representaremos estas situaciones mediante una secuencia de contextos L-fuzzy. Si esta secuencia representa la evolución en el tiempo de un contexto L-fuzzy, intentaremos predecir las tendencias futuras a partir del comportamiento pasado.

En Inteligencia Artificial hay una gran necesidad de representar conocimiento temporal y de modelizar el cambio en el tiempo. En este sentido, este trabajo es un paso más en el estudio de los fenómenos temporales. En concreto, el objetivo del presente trabajo es estudiar en qué medida las relaciones entre los objetos y los atributos mejoran con el paso del tiempo.

Existen trabajos en la literatura que analizan la evolución temporal en un contexto formal, por ejemplo, [27], [30], [31].

En particular, en [30], [31], Wolff introduce un Sistema de Tiempo Conceptual para definir el Análisis de Conceptos Temporales. En este Sistema de Tiempo Conceptual, el estado y la fase se definen como retículos de conceptos que representan el significado de los estados con respecto a la elegida descripción del tiempo. Además, otros autores definen tendencias de evolución en [27], [28], utilizando temporal matching en el caso del Análisis de Conceptos Formales.

La existencia de contextos Triádicos [21] nos da la posibilidad de utilizar relaciones ternarias para representar el tiempo. Sin embargo, esta aproximación es demasiado exigente para nuestro objetivo y, por esta razón, está sólo desarrollada para contextos formales.

El Análisis de Tendencias se refiere habitualmente a técnicas para extraer patrones de comportamiento en estadística. En este trabajo, trabajamos con un nuevo método para contextos L-fuzzy con datos cuantitativos. Este método permitirá establecer tendencias que pueden usarse como base para la toma de decisión. En concreto, profundizaremos en el estudio de las tendencias en la relación entre los objetos y atributos incorporando un nuevo elemento al estudio que representa el grado de evolución de dicha relación cuando es positiva.

Aplicaremos nuestros resultados a un ejemplo que muestra las ventas mensuales de artículos deportivos en determinados establecimientos a lo largo del tiempo.

El trabajo se organiza como sigue: La Sección 2 proporciona un resumen sobre los principales aspectos del Análisis de conceptos L-fuzzy y las sucesiones de contextos L-fuzzy. La sección 3 establece un estudio general sobre tendencias temporales en una sucesión de contextos L-fuzzy definiendo conceptos formales *Trend* y *Persistent* así como niveles de tendencias positivas que nos sirvan para establecer distintas priorizaciones en nuestras predicciones. Mostramos un ejemplo donde aplicamos los resultados en Sección 4. Finalmente, las conclusiones y trabajo futuro se exponen en la Sección 5.

## II. PRELIMINARES

 II-A. Análisis de conceptos  $L$ -fuzzy

En trabajos previos ([10], [11]), hemos definido los contextos  $L$ -fuzzy  $(L, X, Y, R)$ , donde  $L$  es un retículo completo,  $R \in L^{X \times Y}$  es una relación  $L$ -fuzzy entre los objetos de  $X$  y los atributos de  $Y$ . Esta definición es una extensión de los contextos formales de Wille ([18], [29]) que permite trabajar con relaciones entre los objetos y atributos que toman valores en un retículo  $L$ , en lugar de valores binarios.

Para trabajar con estos contextos  $L$ -fuzzy, hemos definido los operadores derivación 1 y 2 por medio de las expresiones:

Para todo  $A \in L^X$ , para todo  $B \in L^Y$

$$A_1(y) = \inf_{x \in X} \{I(A(x), R(x, y))\}$$

$$B_2(x) = \inf_{y \in Y} \{I(B(y), R(x, y))\}$$

con  $I$  un operador de implicación fuzzy definido en el retículo  $(L, \leq)$ . En este trabajo, utilizaremos operadores de implicación residuados y el retículo  $L = [0, 1]$ .

Otros autores han utilizado también estos operadores residuados para definir los operadores derivación ([9], [25], [26]).

La información almacenada en el contexto se visualiza por medio de los conceptos  $L$ -fuzzy, que representan a un grupo de objetos que comparten, ellos y sólo ellos, un grupo de atributos. Estos pares  $(M, M_1) \in L^X \times L^Y$ , donde  $M \in \text{fix}(\varphi)$  es el conjunto de puntos fijos del operador  $\varphi$ , que se define a partir de los operadores derivación 1 y 2 como  $\varphi(M) = (M_1)_2 = M_{12}$ . La primera y la segunda componentes del concepto  $L$ -fuzzy se llaman extensión e intensidad, respectivamente.

Utilizando la relación de orden usual en fuzzy sets, podemos definir el conjunto  $\mathcal{L} = \{(M, M_1) / M \in \text{fix}(\varphi)\}$  con la relación de orden  $\preceq$  dada por:  $(M, M_1), (N, N_1) \in \mathcal{L}$ ,  $(M, M_1) \preceq (N, N_1)$  si  $M \leq N$  (o  $N_1 \leq M_1$ ).

Se demuestra que  $(\mathcal{L}, \preceq)$  es un retículo completo al que llamaremos ([10], [11]) el retículo de conceptos  $L$ -fuzzy.

Además, dados  $A \in L^X$  (o  $B \in L^Y$ ), podemos obtener los conceptos  $L$ -fuzzy asociados aplicando los operadores derivación dos veces. Si utilizamos implicaciones residuadas, como en este trabajo, el concepto  $L$ -fuzzy asociado es  $(A_{12}, A_1)$  (o  $(B_2, B_{21})$ ).

Otros resultados importantes sobre esta teoría, que extiende el Análisis de Conceptos Formales al caso difuso, se pueden encontrar en [6], [8], [9], [12]. Extensiones del Análisis de Conceptos Formales al caso intervalo-valorado están en [13], [3], [16], [17] y a fuzzy property-oriented conceptos en [20], [23].

 II-B. Sucesiones de contextos  $L$ -fuzzy

Un primer estudio de sucesiones de contextos  $L$ -fuzzy cuando  $L = [0, 1]$  se hizo en [5] y [14]. Comenzaremos recordando la definición principal:

**Definición 1.** Una sucesión de contextos  $L$ -fuzzy es una sucesión de tuplas  $(L, X, Y, R_i)$ ,  $i \in \{1, \dots, n\}$ ,  $n \in \mathbb{N}$ , con  $L$  retículo completo,  $X$  e  $Y$  conjuntos de objetos y atributos

respectivamente y  $R_i \in L^{X \times Y}$ , para todo  $i \in \{1, \dots, n\}$ , una familia de relaciones  $L$ -fuzzy entre  $X$  e  $Y$ .

En [1] desarrollamos un estudio general de estas sucesiones de contextos  $L$ -fuzzy utilizando los operadores OWA  $n$ -arios de Lizasoain y Moreno ([22]). Estos operadores son una generalización de los operadores OWA de Yager ([32], [33]).

En ese trabajo y con el fin de extraer la información almacenada en la sucesión de contextos  $L$ -fuzzy, definimos relaciones agregadas utilizando los vectores totalmente ordenados definidos por Lizasoain y Moreno ([22]).

Posteriormente, en [5] hicimos un estudio preliminar en  $[0, 1]$  y en [4] extendimos y profundizamos los resultados para cualquier retículo completo  $L$ . En este caso, tenemos que tener en cuenta que excepto para una cadena completa, los elementos del retículo  $L$  no son necesariamente comparables.

## III. TENDENCIAS TEMPORALES

En [4] analizamos tendencias temporales para identificar la evolución con el tiempo de la sucesión de contextos  $L$ -fuzzy  $(L, X, Y, R_i)$ ,  $i \in \{1, \dots, n\}$ , cuando  $L$  es un retículo completo. Nuestro interés era el estudio de la evolución de la relación entre los objetos (o atributos) respecto de uno o varios atributos (u objetos).

En este trabajo, utilizábamos operadores de implicación residuados en el cálculo de los conceptos  $L$ -fuzzy asociados a ciertos objetos o atributos.

Comenzaremos mostrando en el siguiente apartado los principales resultados del trabajo.

## III-A. Objetos y atributos Trend y Persistent

La mejor manera de estudiar la evolución en el tiempo de un objeto o un atributo es el estudio de sus conceptos  $L$ -fuzzy asociados en los diferentes contextos  $L$ -fuzzy de la sucesión. Esta es la idea de las siguientes definiciones y resultados que dábamos en [4]:

**Definición 2.** Consideremos  $x_0 \in X, y_0 \in Y$ . Sean  $(A_{i\{x_0\}}, B_{i\{x_0\}})$  y  $(A_{i\{y_0\}}, B_{i\{y_0\}})$  los conceptos  $L$ -fuzzy asociados a  $\{x_0\}$  e  $\{y_0\}$  en la sucesión de contextos  $L$ -fuzzy  $(L, X, Y, R_i)$  con  $i \leq n$ .

Entonces, podemos definir:

- (i)  $Trend(x_0) = \{y \in Y / B_{i\{x_0\}}(y) \leq B_{i+1\{x_0\}}(y), \forall i < n\}$  es el conjunto de atributos cuyos grados de pertenencia en las diferentes intensiones de los conceptos  $L$ -fuzzy  $(A_{i\{x_0\}}, B_{i\{x_0\}})$  son no decrecientes.
- (ii)  $Trend(y_0) = \{x \in X / A_{i\{y_0\}}(x) \leq A_{i+1\{y_0\}}(x), \forall i < n\}$  es el conjunto de objetos cuyos grados de pertenencia en las diferentes extensiones de los conceptos  $L$ -fuzzy  $(A_{i\{y_0\}}, B_{i\{y_0\}})$  son no decrecientes.

Podemos decir que son los atributos cada vez más relacionados con el objeto  $x_0$  y los objetos cada vez más relacionados con el atributo  $y_0$ .

Esta es una definición muy exigente pero permite establecer tendencias con un alto grado de cumplimiento.



Además, se puede probar el siguiente resultado:

**Proposición 1.** Consideremos  $x \in X, y \in Y$ .

$$y \in Trend(x) \iff x \in Trend(y)$$

Podemos extender esta definición al caso de más de un objeto o un atributo:

**Definición 3.** Para cada  $Z, T \neq \emptyset, Z \subseteq X$  y  $T \subseteq Y$ , definimos  $Trend(Z)$  y  $Trend(T)$  como:

- (i)  $Trend(Z) = \{y \in Y / B_{i\{x\}}(y) \leq B_{i+1\{x\}}(y),$   
para todo  $i < n$ , para todo  $x \in Z\}$
- (ii)  $Trend(T) = \{x \in X / A_{i\{y\}}(x) \leq A_{i+1\{y\}}(x),$   
para todo  $i < n$ , para todo  $y \in T\}$

En este caso, se puede probar también el siguiente resultado:

**Proposición 2.** Para todo  $Z, T \neq \emptyset, Z \subseteq X$  y  $T \subseteq Y$  :

- (i) Si  $Trend(Z) = T$ , entonces  $Z \subseteq Trend(T)$
- (ii) Si  $Trend(T) = Z$ , entonces  $T \subseteq Trend(Z)$

Como caso particular, tenemos los conjuntos  $Trend(X)$  y  $Trend(Y)$  donde se cumple:

$$Trend(X) = Y \iff Trend(Y) = X.$$

Como la definición de  $Trend$  es muy exigente, en [4] definimos objetos y atributos  $Persistent$  para relajar este nivel de exigencia.

**Definición 4.** Dados  $x_0 \in X, y_0 \in Y$ . Sean  $(A_{i\{x_0\}}, B_{i\{x_0\}})$  y  $(A_{i\{y_0\}}, B_{i\{y_0\}})$  los conceptos  $L$ -fuzzy asociados a los crisp singletons  $\{x_0\}$  e  $\{y_0\}$ , en la sucesión de contextos  $L$ -fuzzy  $(L, X, Y, R_i)$  con  $i \leq n$  :

- (i)  $Persistent(x_0) = \{y \in Y / B_{i\{x_0\}}(y) \geq B_{1\{x_0\}}(y),$   
para todo  $i, 1 < i \leq n\}$

es el conjunto de atributos cuyos grados de pertenencia en las intensiones fuzzy de los conceptos  $L$ -fuzzy  $(A_{i\{x_0\}}, B_{i\{x_0\}})$  son mayores o iguales que los valores correspondientes en el concepto  $L$ -fuzzy  $(A_{1\{x_0\}}, B_{1\{x_0\}})$ .

- (ii)  $Persistent(y_0) = \{x \in X / A_{i\{y_0\}}(x) \geq A_{1\{y_0\}}(x),$   
para todo  $i, 1 < i \leq n\}$

es el conjunto de objetos cuyos grados de pertenencia en las extensiones fuzzy de los conceptos  $L$ -fuzzy  $(A_{i\{y_0\}}, B_{i\{y_0\}})$  son mayores o iguales que los valores correspondientes del concepto  $L$ -fuzzy  $(A_{1\{y_0\}}, B_{1\{y_0\}})$ .

Fijado  $j \leq n$ , se puede dar una definición alternativa de  $Persistent(x_0)$  y  $Persistent(y_0)$  como sigue:

Para todo  $i, j < i \leq n$ ,

$$Persistent_j(x_0) = \{y \in Y / B_{i\{x_0\}}(y) \geq B_{j\{x_0\}}(y)\}$$

$$Persistent_j(y_0) = \{x \in X / A_{i\{y_0\}}(x) \geq A_{j\{y_0\}}(x)\}$$

Con esta definición, resultados similares a los de las proposiciones 1 y 2 se verifican:

**Proposición 3.** Consideremos  $x \in X, y \in Y$ .

$$y \in Persistent(x) \iff x \in Persistent(y)$$

Podemos también extender esta definición al caso de más de un objeto o atributo:

**Definición 5.** Para todo  $Z, T \neq \emptyset, Z \subseteq X$  y  $T \subseteq Y$ , definimos  $Persistent(Z)$  y  $Persistent(T)$  como:

- (i)  $Persistent(Z) = \{y \in Y / B_{i\{x\}}(y) \geq B_{1\{x\}}(y),$   
para todo  $i < n$ , para todo  $x \in Z\}$
- (ii)  $Persistent(T) = \{x \in X / A_{i\{y\}}(x) \geq A_{1\{y\}}(x),$   
para todo  $i < n$ , para todo  $y \in T\}$

**Proposición 4.** For all  $Z, T \neq \emptyset, Z \subseteq X$  y  $T \subseteq Y$  :

- (i) Si  $Persistent(Z) = T$ , entonces  $Z \subseteq Persistent(T)$
- (ii) Si  $Persistent(T) = Z$ , entonces  $T \subseteq Persistent(Z)$

Las definiciones  $Trend$  y  $Persistent$  establecen pares de objetos y atributos que pueden ser usados para un análisis más completo de la evolución de la sucesión de contextos  $L$ -fuzzy  $(L, X, Y, R_i), i \in \{1, \dots, n\}$ .

Siguiendo esta idea y la Definición 2, las tendencias de la sucesión de contextos  $L$ -fuzzy que hemos estudiado se pueden completar con la construcción de matrices  $Trend$  y  $Persistent$ .

**Definición 6.** La Matriz  $Trend TM \subseteq X \times Y$  se define como:

$$TM(x, y) = \begin{cases} 1 & \text{si } y \in Trend(x) (\text{equiv. } x \in Trend(y)) \\ 0 & \text{en otro caso} \end{cases}$$

Por la Proposición 1, para obtener la matriz  $Trend$  es sólo necesario el cálculo de  $Trend(x)$ , para todo  $x \in X$  o análogamente  $Trend(y)$ , para todo  $y \in Y$ .

Podemos considerar ahora el contexto formal  $(X, Y, TM)$  y obtener sus conceptos formales para tener una visión general de las tendencias entre los objetos  $X$  y los atributos  $Y$ .

**Definición 7.** Sea el contexto formal  $(X, Y, TM)$  con  $X$  conjunto de objetos,  $Y$  conjunto de atributos y  $TM \subseteq X \times Y$ . Llamaremos a los conceptos de  $(X, Y, TM)$  conceptos formales  $Trend$ .

Es también posible realizar un estudio paralelo utilizando la definición de  $Persistent$ :

**Definición 8.** La matriz  $PM \subseteq X \times Y$  tal que

$$PM(x, y) = \begin{cases} 1 & \text{si } y \in Persistent(x) (x \in Persistent(y)) \\ 0 & \text{en otro caso} \end{cases}$$

se llama Matriz  $Persistent$ .

Podemos ahora considerar  $(X, Y, PM)$  y calcular sus conceptos formales para obtener información sobre las tendencias entre los objetos de  $X$  y los atributos de  $Y$ .

**Definición 9.** Sea el contexto formal  $(X, Y, PM)$ . Los conceptos formales de  $(X, Y, PM)$  se llamarán conceptos formales  $Persistent$ .

Además, como la definición de  $Persistent$  es menos exigente que la de  $Trend$ , se puede probar de forma sencilla

que  $TM \subseteq PM$ .

Mediante estos resultados utilizando las matrices *Trend* y *Persistent* estudiamos objetos y atributos que mejoran su relación con el tiempo, pero no analizamos cuánto supone esa mejora. Este tema será el que abordaremos en el siguiente apartado.

### III-B. Nivel Trend y Persistent

Con el fin de medir el grado de evolución positiva de las relaciones entre los objetos y los atributos, vamos a definir su nivel de tendencia. Para hacerlo trabajaremos con  $L = [0, 1]$ .

Dados  $x_0 \in X, y_0 \in Y$ . Sean  $(A_{i\{x_0\}}, B_{i\{x_0\}})$  y  $(A_{i\{y_0\}}, B_{i\{y_0\}})$  los conceptos *L*-fuzzy asociados a los crisp singletons  $\{x_0\}$  e  $\{y_0\}$ , en la sucesión de contextos *L*-fuzzy  $(L, X, Y, R_i)$  con  $i \leq n$ :

**Definición 10.** Para cada  $x_0 \in X, y \in Y$ , el nivel *Trend* del objeto  $x_0$  para el atributo  $y$  se define como:

$$TrendLevel(x_0)_y = \begin{cases} B_{n\{x_0\}}(y) - B_{1\{x_0\}}(y) & \text{si } y \in Trend(x_0) \\ 0 & \text{en otro caso} \end{cases}$$

Análogamente, podemos definir para cada  $y_0 \in Y, x \in X$  el nivel *Trend* del atributo  $y_0$  para el objeto  $x$ :

$$TrendLevel(y_0)_x = \begin{cases} A_{n\{y_0\}}(x) - A_{1\{y_0\}}(x) & \text{si } x \in Trend(y_0) \\ 0 & \text{en otro caso} \end{cases}$$

También podemos dar las definiciones para Niveles *Persistent*:

**Definición 11.** Para cada  $x_0 \in X, y \in Y$ , el nivel *Persistent* del objeto  $x_0$  para el atributo  $y$  se define como:

$$PerLevel(x_0)_y = \begin{cases} B_{n\{x_0\}}(y) - B_{1\{x_0\}}(y) & \text{si } y \in Persistent(x_0) \\ 0 & \text{en otro caso} \end{cases}$$

Análogamente, podemos definir para cada  $y_0 \in Y, x \in X$  el nivel *Persistent* del atributo  $y_0$  para el objeto  $x$ :

$$PerLevel(y_0)_x = \begin{cases} A_{n\{y_0\}}(x) - A_{1\{y_0\}}(x) & \text{si } x \in Persistent(y_0) \\ 0 & \text{en otro caso} \end{cases}$$

Es fácil comprobar que se cumple el siguiente resultado:

**Proposición 5.** Para todo  $x \in X, y \in Y$ ,

$$TrendLevel(x)_y = TrendLevel(y)_x$$

$$PerLevel(x)_y = PerLevel(y)_x$$

*Demostración.* Si consideramos los crisp singletons  $\{x\}$  e  $\{y\}$  y utilizamos una implicación residuada,  $B_{i\{x\}}(y) = R_i(x, y) = A_{i\{y\}}(x)$ , para todo  $i \leq n$ . Como además  $y \in Trend(x)$  si y sólo si  $x \in Trend(y)$ , y análogamente para la definición de *Persistent*, la proposición se verifica.  $\square$

Podemos establecer relaciones que nos almacenen estos valores:

**Definición 12.** Las matrices *TrendLevelM*, *PerLevelM*  $\in L^{X \times Y}$  se definen como:

$$TrendLevelM(x, y) = TrendLevel(x)_y = TrendLevel(y)_x$$

$$PerLevelM(x, y) = PerLevel(x)_y = PerLevel(y)_x$$

Aunque en la definición dada hemos tomado como intervalo temporal el que va desde el instante inicial al final, sería posible también trabajar con otros intervalos:

**Definición 13.** Dados  $1 \leq j \leq k \leq n$ , para cada  $x_0 \in X, y \in Y$ , el nivel *Trend* y *Persistent* del objeto  $x_0$  para el atributo  $y$  en el intervalo  $[j, k]$  se define como:

$$TrendLevel_{j,k}(x_0)_y = \begin{cases} B_{k\{x_0\}}(y) - B_{j\{x_0\}}(y) & \text{si } y \in Trend_{j,k}(x_0) \\ 0 & \text{en otro caso} \end{cases}$$

$$PerLevel_{j,k}(x_0)_y = \begin{cases} B_{k\{x_0\}}(y) - B_{j\{x_0\}}(y) & \text{si } y \in Persistent_{j,k}(x_0) \\ 0 & \text{en otro caso} \end{cases}$$

donde  $y \in Trend_{j,k}(x_0)$  si  $y \in Trend(x_0)$  en el intervalo  $[j, k]$  e  $y \in Persistent_{j,k}(x_0)$  si  $y \in Persistent(x_0)$  en el intervalo  $[j, k]$ .

Análogamente, dados  $1 \leq j \leq k \leq n$ , podemos definir para cada  $y_0 \in Y, x \in X$  el nivel *Trend* y *Persistent* del atributo  $y_0$  para el objeto  $x$  en el intervalo  $[j, k]$ :

$$TrendLevel_{j,k}(y_0)_x = \begin{cases} A_{k\{y_0\}}(x) - A_{j\{y_0\}}(x) & \text{si } x \in Trend_{j,k}(y_0) \\ 0 & \text{en otro caso} \end{cases}$$

$$PerLevel_{j,k}(y_0)_x = \begin{cases} A_{k\{y_0\}}(x) - A_{j\{y_0\}}(x) & \text{si } x \in Persistent_{j,k}(y_0) \\ 0 & \text{en otro caso} \end{cases}$$

donde  $y \in Trend_{j,k}(x_0)$  si  $y \in Trend(x_0)$  en el intervalo  $[j, k]$  e  $y \in Persistent_{j,k}(x_0)$  si  $y \in Persistent(x_0)$  en el intervalo  $[j, k]$ .

A continuación, podemos definir el nivel *Trend* o *Persistent* de un objeto o de un atributo, agregando valores.

**Definición 14.** Para cada  $x_0 \in X, y_0 \in Y$ :

$$TrendLevel(x_0) = Agr_{y \in Y}(TrendLevel(x_0)_y)$$

$$TrendLevel(y_0) = Agr_{x \in X}(TrendLevel(y_0)_x)$$

$$PerLevel(x_0) = Agr_{y \in Y}(PerLevel(x_0)_y)$$

$$PerLevel(y_0) = Agr_{x \in X}(PerLevel(y_0)_x)$$

Al igual que en el caso anterior, podríamos dar estas definiciones para los contextos del intervalo  $[j, k]$ .

Esta definición nos permite establecer relaciones de preorden en el conjunto de objetos y de atributos de acuerdo con el incremento de su evolución positiva en el tiempo.

**Definición 15.** Dados  $z_i, z_j \in X$  o  $z_i, z_j \in Y$ , definimos las relaciones  $\leq_{TL}$  y  $\leq_{PL}$  como:

$$z_i \leq_{TL} z_j \text{ si } TrendLevel(z_i) \leq TrendLevel(z_j)$$

$$z_i \leq_{PL} z_j \text{ si } PerLevel(z_i) \leq PerLevel(z_j)$$



**Proposición 6.** Las relaciones  $\leq_{TL}$  y  $\leq_{PL}$  son preordenes.

*Demostración.* Ya que los valores de *TrendLevel* y *PerLevel* son valores en  $[0,1]$ , es obvio por la definición que se trata de relaciones reflexivas y transitivas. Sin embargo, no son relaciones de orden por no cumplirse la antisimetría.  $\square$

Utilizando  $\leq_{TL}$  y  $\leq_{PL}$  podemos también establecer rankings en el conjunto de objetos  $X$  y de atributos  $Y$  de nuestra sucesión de contextos. Aquellos objetos o atributos con mayores valores de *TrendLevel* y *PerLevel* serán los que hayan evolucionado de forma más positiva a lo largo del tiempo. La elección entre ambos rankings dependerá de nuestro nivel de exigencia.

Por otro lado, mediante las matrices *TrendLevelM* y *PerLevelM* podemos establecer relaciones en los conceptos *Trend* y *Persistent* definidos a partir de los contextos formales  $(X, Y, TM)$  y  $(X, Y, PM)$  que nos permitan establecer qué conceptos son más relevantes que otros. El procedimiento que seguiremos será el siguiente:

- (1) Obtención de las matrices *TrendLevelM* y *PerLevelM*
- (2) Obtención de las matrices *TM* y *PM*
- (3) Cálculo de los conceptos formales de los contextos formales  $(X, Y, TM)$  y  $(X, Y, PM)$
- (4) Cálculo del peso de cada concepto  $(A, B)$  de  $(X, Y, TM)$  y  $(X, Y, PM)$  definido como:

$$W_{TM}((A, B)) = \begin{cases} \sum_{x_k \in A, y_l \in B} TrendLevelM(x_k, y_l) & \text{si } A, B \neq \emptyset \\ 0 & \text{en otro caso} \end{cases}$$

$$W_{PM}((A, B)) = \begin{cases} \sum_{x_k \in A, y_l \in B} PerLevelM(x_k, y_l) & \text{si } A, B \neq \emptyset \\ 0 & \text{en otro caso} \end{cases}$$

- (5) Ordenación de los conceptos formales de acuerdo con su peso estableciendo rankings.

#### IV. EJEMPLO PRÁCTICO

Vamos a mostrar la aplicación de los resultados utilizando el siguiente caso práctico:

Sea  $(L, X, Y, R_i), 1 \leq i \leq n$  una secuencia de contextos fuzzy que representa las ventas de artículos deportivos ( $X$ ) en establecimientos ( $Y$ ) a lo largo de un periodo de tiempo. Queremos estudiar los lugares y los artículos en los que ha habido un mayor incremento de ventas teniendo en cuenta que hay artículos que se venden sólo en ciertas estaciones (por ejemplo, skis o trajes de baño) y en ciertas zonas (es más posible vender skis en Colorado que en Florida). Tomaremos  $L = [0, 1]$ .

$$R_1 = \begin{pmatrix} 0.7 & 1 & 0.8 \\ 0 & 0.1 & 0.1 \\ 0 & 0.1 & 0 \end{pmatrix} R_2 = \begin{pmatrix} 1 & 0.8 & 1 \\ 0.2 & 0.4 & 0.1 \\ 0 & 0 & 0.2 \end{pmatrix}$$

$$R_3 = \begin{pmatrix} 1 & 1 & 1 \\ 0.6 & 0.5 & 0.7 \\ 0 & 0.1 & 0.2 \end{pmatrix} R_4 = \begin{pmatrix} 0.5 & 0.4 & 0.6 \\ 0.1 & 0.5 & 0.3 \\ 0.6 & 0.8 & 0.8 \end{pmatrix}$$

$$R_5 = \begin{pmatrix} 0.1 & 0 & 0 \\ 0 & 0.7 & 0 \\ 0.8 & 1 & 0.9 \end{pmatrix}$$

En este caso obtendríamos las siguientes matrices *Trend* y *Persistent* :

<i>TM</i>	$y_1$	$y_2$	$y_3$	<i>PM</i>	$y_1$	$y_2$	$y_3$
$x_1$	0	0	0	$x_1$	0	0	0
$x_2$	0	1	0	$x_2$	1	1	0
$x_3$	1	0	1	$x_3$	1	0	1

Vamos a continuar con el desarrollo para el contexto  $(X, Y, PM)$ , pudiendo hacer uno paralelo para  $(X, Y, TM)$ . Los conceptos formales de  $(X, Y, PM)$  son los siguientes:

- $(\{x_1\}, \emptyset)$
- $(\{x_2\}, \{y_1, y_2\})$
- $(\{x_3\}, \{y_1, y_3\})$
- $(\{x_2, x_3\}, \{y_1\})$
- $(\emptyset, \{y_1, y_2, y_3\})$

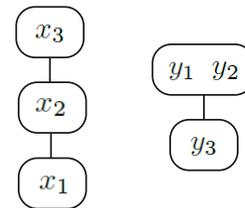
Podemos ahora calcular la matriz *PerLevelM*. El resultado es el siguiente:

<i>PerLevelM</i>	$y_1$	$y_2$	$y_3$
$x_1$	0	0	0
$x_2$	0.6	0.4	0
$x_3$	0.8	1	0.9

Si tomamos la media como agregación, obtenemos los valores:

$$\begin{aligned} PerLevel(x_1) &= 0 \\ PerLevel(x_2) &= 0.33 \\ PerLevel(x_3) &= 0.9 \\ PerLevel(y_1) &= 0.47 \\ PerLevel(y_2) &= 0.47 \\ PerLevel(y_3) &= 0.3 \end{aligned}$$

que nos permiten establecer los siguientes rankings en el conjunto de objetos y de atributos:

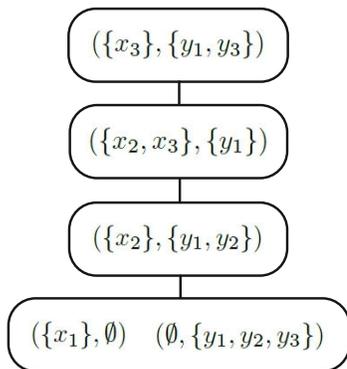


Por tanto, podemos decir que el artículo  $x_3$  y los establecimientos  $y_1$  e  $y_2$  son los que han experimentado en media un mayor incremento en sus ventas. En contra, el artículo  $x_1$  y el establecimiento  $y_3$  tienen los incrementos de ventas menores.

Por otra parte, utilizaremos la matriz *PerLevelM* para ordenar los conceptos de mayor a menor relevancia aplicando el procedimiento descrito en el apartado anterior:

$$\begin{aligned} W_{PM}((\{x_1\}, \emptyset)) &= 0 \\ W_{PM}((\{x_2\}, \{y_1, y_2\})) &= 1 \\ W_{PM}((\{x_3\}, \{y_1, y_3\})) &= 1.7 \\ W_{PM}((\{x_2, x_3\}, \{y_1\})) &= 1.4 \\ W_{PM}((\emptyset, \{y_1, y_2, y_3\})) &= 0 \end{aligned}$$

Por tanto, podemos establecer el siguiente ranking de conceptos (la relevancia de los distintos conceptos disminuye de arriba hacia abajo en el gráfico).



Como conclusión podríamos decir que: *El mayor incremento de ventas ha sido en del artículo  $x_3$  en las ciudades  $y_1$  e  $y_3$ . A continuación tendríamos los artículos  $x_2$  y  $x_3$  en  $y_1$ . Finalmente,  $x_2$  en  $y_1$  e  $y_2$ .*

#### V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo hemos continuado con el estudio de tendencias en una sucesión de contextos  $L$ -fuzzy que representa la evolución en el tiempo de un contexto  $L$ -fuzzy. Con la introducción de los niveles de tendencias (*Trend* y *Persistence* Level) hemos podido establecer qué objetos y atributos son los que sus valores más han aumentado con el paso del tiempo. Además hemos introducido las Matrices *Trend* y *Persistent* level que nos han permitido establecer rankings en los conceptos formales que nos establecen las tendencias en la relación entre los objetos y los atributos de la sucesión de contextos  $L$ -fuzzy.

En el futuro queremos analizar no sólo tendencias positivas, sino también las negativas.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente subvencionado por el Grupo de Investigación “Sistemas Inteligentes y Energía (SI+E)” de la Universidad del País Vasco - UPV/EHU (Proyecto GIU 16/54), y por el Grupo de Investigación “Inteligencia Artificial y Razonamiento Aproximado” de la Universidad Pública de Navarra y el Gobierno Español (Proyecto TIN2016-77356-P (MINECO, AEI/FEDER, UE))

#### REFERENCIAS

[1] C. Alcalde, A. Burusco:  $L$ -fuzzy context sequences on complete lattices, IPMU 2014, *Lecture Notes in Computer Science* Part III, CCIS 444, pp. 31–40, 2014.

[2] C. Alcalde, A. Burusco: The use of two relations in  $L$ -fuzzy contexts, *Information Sciences* 301 (1), pp. 1–12, 2015.

[3] C. Alcalde, A. Burusco, R. Fuentes-González, I. Zubia: Treatment of  $L$ -fuzzy contexts with absent values, *Information Sciences* 179 (1-2), pp. 1–15, 2009.

[4] C. Alcalde, A. Burusco, H. Bustince, A. Jurio, J.A. Sanz: Evolution in time of the  $L$ -fuzzy context sequences, *Information Sciences* 326, pp. 202–214, 2016.

[5] C. Alcalde, A. Burusco, R. Fuentes-González: The study of fuzzy context sequences *International Journal of Computational Intelligence Systems* 6 (3), pp. 518–529, 2013.

[6] C. Alcalde, A. Burusco, R. Fuentes-González: Application of the  $L$ -fuzzy concept analysis in the morphological image and signal processing, *Annals of Mathematics and Artificial Intelligence* 72 (1-2), pp. 115–128, 2014.

[7] L. Antoni, S. Krajci, O. Kridlo, B. Macek, L. Pisková: On heterogeneous formal contexts, *Fuzzy Sets and Systems* 234, pp. 2–33, 2014.

[8] R. Bělohlávek: Fuzzy Galois Connections, *Math. Logic Quarterly* 45 (4), pp. 497–504, 1999.

[9] R. Bělohlávek, V. Vychodil: What is a fuzzy concept lattice, in *Proceedings of the Third International Conference on Concept Lattice and their Applications, CLA 2005*, Olomouc, Czech Republic, pp. 34–45, 2005.

[10] A. Burusco, R. Fuentes-González: The Study of the  $L$ -fuzzy Concept Lattice, *Mathware and Soft Computing* 1 (3), pp. 209–218, 1994.

[11] A. Burusco, R. Fuentes-González: Construction of the  $L$ -fuzzy Concept Lattice, *Fuzzy Sets and Systems* 97 (1), pp. 109–114, 1998.

[12] A. Burusco, R. Fuentes-González: Concept lattices defined from implication operators, *Fuzzy Sets and Systems* 114 (1), pp. 431–436, 2000.

[13] A. Burusco, R. Fuentes-González: The study of the interval-valued contexts, *Fuzzy Sets and Systems* 121, pp. 69–82, 2001.

[14] C. Alcalde, A. Burusco, R. Fuentes-González: Application of OWA Operators in the  $L$ -fuzzy Concept Analysis in *Aggregation Functions in Theory and Practice*. Book Series: Advances in Intelligent Systems and Computing 228, pp. 129–140, 2013.

[15] P. Butka, J. Pócs, J. Pósová: On equivalence of conceptual scaling and generalized one-sided concept lattices, *Information Sciences* 259, pp. 57–70, 2014.

[16] Y. Djouadi, H. Prade: Interval-Valued Fuzzy Galois Connections: Algebraic Requirements and Concept Lattice Construction, *Fundamenta Informaticae* 99 (2), pp. 169–186, 2010.

[17] Y. Djouadi, H. Prade: Possibility- theoretic extension of derivation operators in formal concept analysis over fuzzy lattices, *FODM* 10 (4), pp. 287–309, 2011.

[18] B. Ganter, R. Wille: Formal concept analysis: Mathematical foundations, Springer, Berlin - New York, 1999.

[19] J. Konecny: Isotone fuzzy Galois connections with hedges, *Information Sciences* 181 (10) pp. 1804–1817, 2011.

[20] H. Lai, D. Zhang: Concept lattices of fuzzy contexts: Formal concept analysis vs. rough set theory, *International Journal of Approximate Reasoning* 50 (5) pp. 695–707, 2009.

[21] F. Lehmann, R. Wille: A triadic approach to Formal concept analysis, *Conceptual structures: applications, implementation and theory*, Lecture Notes in Artificial Intelligence 954, pp. 32–43, 1995.

[22] I. Lizasoain, C. Moreno: OWA operators defined on complete lattices, *Fuzzy Sets and Systems* 224, pp. 36–52, 2013.

[23] J. Medina: Multi-adjoint property-oriented and object-oriented concept lattices, *Information Sciences* 190, pp.95–106, 2012.

[24] J. Medina, M. Ojeda-Aciego, J. Ruiz Calvino: Formal concept analysis via multi-adjoint concept lattices, *Fuzzy Sets and Systems* 160 (2), pp. 130–144, 2009.

[25] J. Medina, M. Ojeda-Aciego: Multi-adjoint  $t$ -concept lattices, *Information Sciences* 180 (5), pp. 712–725, 2010.

[26] J. Medina, M. Ojeda-Aciego, Dual multi-adjoint concept lattices, *Information Sciences* 225, 47–54, 2013.

[27] R. Neouchi, A. Y. Tawfik, R. A. Frost: Towards a Temporal Extension of Formal Concept Analysis. In *Proceedings of Canadian Conference on Artificial Intelligence*, pp. 335–344, 2001.

[28] A. Y. Tawfik, G. Scott: Temporal Matching under Uncertainty. In *Proceedings of the Eighth International Workshop on Artificial Intelligence and Statistics*, 2001.

[29] R. Wille: Restructuring lattice theory: an approach based on hierarchies of concepts, in: *Rival I. (Ed.), Ordered Sets, Reidel, Dordrecht-Boston*, pp. 445–470, 1982.

[30] K. E. Wolff: States, Transitions, and Life Tracks in Temporal Concept Analysis, *Formal Concept Analysis*, pp. 127–148, 2005.

[31] K. E. Wolff: Temporal Relational Semantic Systems, *ICCS*, pp. 165–180, 2010.

[32] R.R. Yager: On ordered weighted averaging aggregation operators in multi-criteria decision making, *IEEE Transactions on Systems, Man and Cybernetics* 18, pp. 183–190, 1988.

[33] R.R. Yager: Families of OWA operators, *Fuzzy Sets and Systems* 59, pp. 125–148, 1993.



# Procesamiento Semántico Difuso Aplicado a un Modelo de Análisis de Textos basado en Grafos

Wenny Hojas-Mazo, Alfredo Simón-Cuevas  
Universidad Tecnológica de La Habana “José Antonio Echeverría”, Cujae  
Ave. 114, No. 11901, CP: 19390, La Habana, Cuba  
{whojas, asimon}@ceis.cujae.edu.cu

José A. Olivas, Francisco P. Romero  
Universidad de Castilla La Mancha  
Paseo de la Universidad, 4, Ciudad Real, España  
{JoseAngel.Olivas, FranciscoP.Romero}@uclm.es

**Resumen**— La obtención de información relevante y conocimiento en textos aún constituye un gran desafío. En este trabajo, se presenta un enfoque de análisis de textos basado en grafos, soportado en el procesamiento semántico difuso del contenido. En esta propuesta se combinan procesos de consultas sobre los grafos obtenidos de los textos, la recomendación de conceptos relevantes y la recuperación de pasajes de texto, incluyendo mecanismos de integración semántica de los grafos como parte de las consultas. La propuesta fue evaluada en el análisis de artículos científicos con resultados prometedores.

**Palabras clave** — análisis de textos; representación de textos en grafos; análisis semántico difuso; integración semántica de grafos

## I. INTRODUCCIÓN

El gran volumen de información no estructurada actualmente disponible en textos constituye un recurso muy valioso. El procesamiento y análisis efectivo de esas fuentes textuales, para obtener información relevante y conocimiento, aún es una tarea desafiante, demandándose mayor atención a las soluciones de minería de texto [1]. Los textos han sido procesados usando diferentes tipos de representación, donde las bolsas de palabras y los modelos vectoriales son los más usados, fundamentalmente en la recuperación de información. Sin embargo, estas soluciones se enfocan más en facilitar el acceso a los textos, y no en el análisis de su contenido para descubrir patrones y conocimiento, siendo este uno de los objetivos principales del análisis de textos. En este sentido, el uso de grafos surge como alternativa prometedora para el análisis y exploración de las estructuras conceptuales de los textos [13].

En este trabajo, se presenta un modelo de análisis de textos basado en grafos, en el que se propone un enfoque difuso para el tratamiento semántico del contenido. En este modelo, el contenido conceptual de los textos es representado en grafos, y se combina el uso de consultas sobre los grafos, la identificación de conceptos relevantes y la recuperación de pasaje, para obtener estructuras conceptuales interesantes e información textual útil asociada. Las consultas están concebidas sobre la base de la integración semántica de los grafos, para lo cual se propone un enfoque difuso mediante la aplicación de la agregación compensatoria [22] de medidas de similitud sintáctica y semántica. Este enfoque ofrece mayor diversidad, en cuanto al análisis del contenido textual, respecto a lo reportado en [5][21][12]. La aplicabilidad del modelo

propuesto se evaluó en las tareas de extracción y síntesis de datos en la revisión sistemática de la literatura (SRL: *Systematic Literature Review*) reportada en [8], para soportar estas tareas al recuperar información relevante que apoye a los revisores en la extracción de datos de los artículos y la búsqueda de respuestas a las preguntas de investigación planteadas. El desarrollo de este caso de estudio ejemplifica como el modelo propuesto ofrece soporte computacional a las tareas de extracción y síntesis de datos en una SRL. Las principales contribuciones de este trabajo se resumen en: (1) la aplicación de la lógica difusa en la integración semántica de grafos, basada en la agregación compensatoria [22] de medidas de similitud sintáctica y semántica para evaluar la similitud entre conceptos en los grafos; y (2) la combinación de técnicas de análisis de grafo, tales como: consultas e identificación de conceptos relevantes, y la recuperación de pasajes de texto, para obtener estructuras conceptuales interesantes e información textual útil asociada.

El resto del trabajo está organizado de la siguiente manera: la Sección 2 expone algunos fundamentos teóricos del problema; la Sección 3 describe el enfoque propuesto; la Sección 4 presenta los resultados del caso de estudio desarrollado; y la Sección 5 expone las conclusiones arribadas e ideas de trabajo futuro.

## II. ANÁLISIS DE TEXTOS MEDIANTE GRAFOS

La representación de textos basada en grafos evita la pérdida de información contextual y semántica del contenido, y reduce la dispersión de los conceptos y la información en su procesamiento. A través de un grafo, el texto se reduce a un número relativamente pequeño de conceptos y relaciones, por lo que una colección de textos puede ser fácilmente manejada y analizada computacionalmente. En este sentido, el empleo de técnicas y herramientas de procesamiento de grafos facilita la obtención de información y conocimiento a partir de esa representación, así como realizar análisis cualitativos y cuantitativos sobre los conceptos incluidos en un texto, para identificar conceptos fuertemente relacionados, estructuras conceptuales interesantes, conceptos relevantes, entre otras. Las operaciones sobre los grafos (ej. Unión) son una de esas herramientas útiles en este sentido [21]. Estos beneficios se evidencian en: detección de tópicos [7], la recuperación de información [4][14], y en varias revisiones [11][7][21]. Sin

embargo, solo se identificaron dos soluciones orientadas al análisis del contenido de textos representados en grafos y enfocada a conceptos [5][12].

En [5] se propone un enfoque basado en la construcción automática de grafos etiquetados con n-gramas de tamaño variable a partir de textos y en la aplicación de operaciones sobre los mismos para identificar y representar los tópicos principales de uno o más textos. En la construcción del grafo, el texto se segmenta en oraciones y se extraen los tokens, y estos son clasificados en: Ignorar (determinantes, pronombres y adverbios), Arco (conjunciones, preposiciones y verbos) y Nodo (secuencia de tokens no asociada a los anteriores), siendo estos dos últimos los utilizados para construir el grafo. Este método solo extrae relaciones explícitas del texto, por lo que es susceptible a que se representen elementos aislados en el grafo, lo cual impacta negativamente en los resultados del análisis a realizar a través de consultas y algoritmos de identificación de conceptos relevantes representados en grafos. En la modelación de los tópicos, inicialmente se genera un grafo por cada documento, luego se integran los grafos en uno solo aplicando la operación Unión. Posteriormente, se obtiene un ranking de relevancia de los nodos del grafo resultante y se aplica la operación de Proyección sobre los  $k$  nodos más relevantes, para obtener un sub-grafo que modela los tópicos. En esta propuesta, la integración de los grafos que se produce en la operación de Unión se basa en la equivalencia sintáctica de los nodos, sin considerar la semántica subyacente. Esto representa una debilidad, ya que se puede producir la integración de contenidos sin vínculos semánticos entre ellos, dado que los conceptos representados en los nodos pueden estar sujetos a ambigüedades. Este problema es solucionado de alguna manera en [12], donde se propone un enfoque similar de análisis a partir de grafos construidos automáticamente de los textos, pero más enfocado al análisis de conceptos y ofreciendo un mecanismo de operaciones de consulta sobre grafos más abarcador y flexible, que incluye operaciones de: Unión, Intersección y Proyección. En el caso de esta última, se ofrece mayor facilidad al usuario, ya que estos son los que seleccionan los conceptos de interés sobre los que se desea realizar el análisis. En esta solución, se incluye un método de análisis semántico para la búsqueda e integración de estructuras conceptuales de los grafos, soportado por un algoritmo de desambiguación y WordNet, el cual se aplica en el procesamiento de cada consulta. No obstante, también con la desventaja de que, como se plantea en [18], el tratamiento de la semántica basada en la desambiguación aumenta la complejidad de la solución y los recursos de cómputo requeridos, sugiriéndose el uso de técnicas de evaluación de similitud semántica, tales como las basadas en WordNet [20]. Además, estas soluciones no brinda una forma para conocer las fuentes textuales de las cuales provienen los conceptos y/o temas relevantes o de contexto, lo cual enriquecería y proporcionaría más fiabilidad al análisis de texto.

### III. MODELO DE ANÁLISIS PROPUESTO

El modelo incluye tres procesos fundamentales: representación de textos, análisis de grafos y recuperación de pasajes, e integra varios recursos de conocimiento, según se muestra en la Fig. 1. El primero, tiene el objetivo de estructurar

el contenido textual mediante su representación en forma de grafo, a partir del cual se conforma un Repositorio de Grafos de Conocimiento (RGC), y usando n-gramas para la indexación de los textos. Los restantes procesos ofrecen la posibilidad al usuario de recuperar información relevante y obtener conocimiento desde esos contenidos estructurados, a través de consultas sobre el RGC, la identificación y recomendación de conceptos relevantes y la recuperación de pasajes de textos donde aparecen conceptos de interés. Este último da un valor agregado al análisis de conceptos con respecto al resto de las propuestas, pues permite identificar las fuentes textuales donde aparecen los conceptos, obteniendo un análisis más detallado.

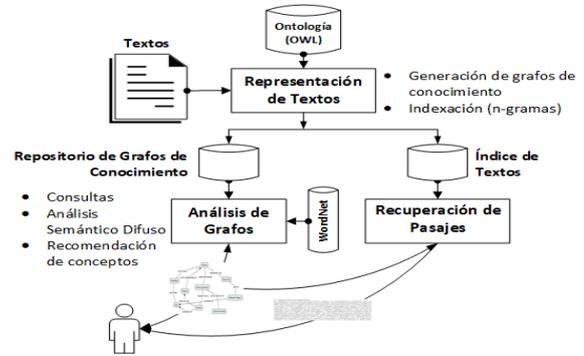


Fig. 1. Visión general del modelo propuesto

#### A. Representación de los Textos

En este proceso, el contenido de los textos es representado mediante dos esquemas: (1) grafos y (2) n-gramas, siendo el primero de ellos, la principal fuente de análisis del contenido textual. La generación del grafo está concebida de forma similar a lo reportado en [12], en tres fases: pre-procesamiento, extracción de conceptos y de relaciones. En el pre-procesamiento, se extrae la información sintáctica y gramatical del texto usando varias técnicas de procesamiento de lenguaje natural (NLP: *Natural Language Processing*) a través de FreeLing, en especial el análisis de dependencia, que aunque es más costoso computacionalmente que el análisis superficial ha dado mejores resultados [10]. Los conceptos se extraen empleando un conjunto de patrones léxico-sintácticos (representan mayoritariamente frases sustantivas) y a través del vocabulario representado en una ontología suministrada por el usuario (preferiblemente del mismo ámbito del texto). La extracción de relaciones abarca la identificación de relaciones explícitas e implícitas entre los conceptos identificados. Las explícitas se extraen de cada oración usando también patrones léxico-sintácticos y las implícitas (conectan conceptos que aparecen en diferentes partes del texto) se extraen mediante la técnica de string matching, el análisis de la proximidad entre conceptos en el texto y tenido en cuenta relaciones representadas en la ontología (si es suministrada). Este último tipo de relaciones permite incrementar la cobertura del texto, en cuanto a la representación de su contenido, aspecto clave para aumentar la eficacia en su análisis. Luego de la extracción de los conceptos y relaciones, se eliminan redundancias e inconsistencias, y se genera el grafo de cada texto. El uso de n-gramas está motivado por la necesidad de crear un índice de los textos, que permita la recuperación de contenidos textuales asociados a conceptos recuperados como resultados de las



consultas a los grafos, siendo esta una funcionalidad a través de la cual se extiende lo reportado en [12]. Los conceptos representados en los grafos pueden constituir secuencias de tokens dentro de las oraciones, por tanto, el uso de n-gramas facilita la recuperación de aquellas oraciones en las cuales estén presentes esos conceptos. La indexación se lleva a cabo segmentando los textos en oraciones, extrayendo de ellas los n-gramas (1-, 2-, y 3-gramas) y almacenándolas con esa estructura en un índice de Lucene. Ambos procesos de estructuración del contenido de los textos se ejecutan en paralelo.

## B. Análisis de Grafos

El proceso de análisis de grafos se lleva a cabo mediante un mecanismo de consultas basado en [5][12], con la diferencia de que en esta nueva solución se propone un enfoque difuso para realizar el análisis semántico que se lleva a cabo en la integración de los grafos, como parte del procesamiento de las consultas. Adicionalmente, se incluye la identificación y recomendación de conceptos relevantes mediante la obtención de un ranking de conceptos, similar a lo reportado en [5], pero teniendo en cuenta como elementos: la frecuencia de aparición de los conceptos en los textos y la relevancia obtenida por el algoritmo PageRank [6], aplicado sobre el grafo que representa el contenido de la colección de textos.

### 1) Consultas

A través de estas consultas, se puede recuperar información relevante y obtener conocimiento desde un espacio de búsqueda especificado por el usuario y constituido por un conjunto de grafos almacenados en el RGC. El resultado de las consultas se puede expresar en conceptos individuales y/o estructuras conceptuales en forma de grafo. El procesamiento de las consultas incluye tareas de búsqueda e integración de información, por lo que, aunque los conceptos recuperados estén presentes en diferentes fuentes textuales, estos pueden ser integrados en el resultado final, propiciando así la generación de conocimiento. Los tipos de consultas incluidas en este proceso son: Unión, Intersección y Proyección.

La unión de dos grafos  $G_1 = (N_1, E_1)$  y  $G_2 = (N_2, E_2)$  se denota como  $G_1 \cup G_2$  y de la misma manera  $(N_1 \cup N_2, E_1 \cup E_2)$ . El grafo unión se puede ver como una forma de mezclar dos grafos sin ninguna pérdida de información (es decir, sin excluir ningún nodo  $N_i$ , ni arco  $E_i$ ). Por tanto, es un operador útil para mezclar información de múltiples documentos de texto [5]. En efecto, si se considera el corpus  $D = \{d_1, \dots, d_n\}$  y si  $G_i$  denota el modelo de grafo correspondiente para cada  $d_i$ , entonces la información combinada del corpus se puede representar por:

$$G_D = \bigcup_{i=1}^n G_i$$

Esta representación conlleva un rápido crecimiento del número de nodos y por consiguiente la obtención de una cantidad abrumadora de información. Por tanto, el uso de la unión de grafos para mezclar documentos textuales requiere típicamente post-procesamiento con un operador que extraiga la información relevante del grafo combinado [5].

La *Intersección (Inter)* permite recuperar conceptos y estructuras conceptuales comunes a un % (cota mínima) de los grafos que conforman el espacio de búsqueda, el cual requiere ser especificado por el usuario como parámetro, y es definido como Valor de Soporte (VS) [12]. La *Proyección (Proj<sup>R</sup>)*, en sus diferentes variantes, permite recuperar las estructuras conceptuales asociadas a determinados conceptos de interés especificados por el usuario, considerando diferentes niveles de vecindad (denotado por  $R$ ); el cual también es especificado por el usuario. Se utilizan tres tipos de consultas *Proyección*, para ofrecer diferentes perspectivas de recuperación de información, considerando sobre el concepto de interés: (1) solo enlaces de entrada ( $Proj^{R, IN}$ ); (2) solo enlaces de salida ( $Proj^{R, OUT}$ ); y (3) todos los tipos de enlaces ( $Proj^R$ ). Las primeras dos, son útiles para analizar los niveles de autoridad o centralidad de los conceptos de interés, respecto a otros conceptos con los que está relacionado en el texto; inspirado en los conceptos de Kleinberg [16]. Notar que esta consulta puede conducir a un subgrafo que formado por varios componentes (mutuamente desconectados). La *Intersección* y *Proyección* también ofrecen la posibilidad de obtener automáticamente resúmenes de la colección de textos, desde diferentes perspectivas, ya sea general (*Intersección*) o enfocados a conceptos de interés (*Proyección*).

### 2) Análisis Semántico Difuso

En el modelo propuesto, el proceso análisis semántico se lleva a cabo con el objetivo de integrar la información contenida en la colección de textos a través de la integración de los grafos que representan sus estructuras conceptuales. Este proceso se ejecuta como parte del procesamiento de las consultas definidas para la obtención de resultados sobre un contenido semánticamente integrado, aunque provenga de fuentes textuales diferentes. La integración de los grafos está basada en la integración de conceptos semánticamente similares. En [12] este proceso se realiza a partir de la identificación del sentido en WordNet de los conceptos (usando un algoritmo de desambiguación) y la unificación de aquellos que tengan el mismo significado. Sin embargo, el análisis semántico de la información textual, a nivel del significado de las palabras, está usualmente sujeto a la subjetividad, vaguedad y problemas de imprecisión, dada la inherente ambigüedad del lenguaje natural. Debido a esto y a las limitaciones mencionadas sobre el uso de algoritmos de desambiguación en este tipo de enfoques, es que se decide tratar este problema desde la perspectiva de la lógica difusa.

En esta nueva propuesta, el análisis de la similitud semántica difusa entre los conceptos se lleva a cabo mediante la combinación de la medida de similitud sintáctica de Levenshtein [17], con otras tres medidas de similitud semántica definidas sobre la base de lo reportado en [18] para medir la similitud sentencia-a-sentencia y varias de las medidas disponibles en el paquete WordNet::Similarity [20] (Resnik - R, Lin - LIN, and Jiang & Conrath - J & C)); un enfoque similar se aplica en [2]. Esta combinación se realiza a través de la función de agregación compensatoria reportada en [22] (ecuaciones 1 y 2) y la *t-norma* algebraica descrita en la ecuación (3), obteniendo un solo valor de similitud entre conceptos a partir de los valores numéricos ( $s_i$ ) resultantes de

cada medida. En el campo de la medición de similitud semántica, las funciones de agregación son generalmente definidas y usadas para combinar varios valores numéricos, a partir de la agregación de los resultados de diferentes medidas de similitud semántica para obtener un único valor resultante [19]. El flujo de esta propuesta se muestra en Fig. 2, y la misma permite reducir los efectos negativos derivados de la incertidumbre que se produce en la decisión sobre qué medidas son más relevantes y el peso que ha dicha relevancia se asigna.

$$Z_\gamma(s_1, s_2, \dots, s_n) = \left( \prod_{i=1}^n s_i \right)^{1-\gamma} * \left( 1 - \prod_{i=1}^n (1 - s_i) \right)^\gamma \quad (1)$$

$$\gamma = \frac{T(s_1, s_2, \dots, s_n)}{T(s_1, \dots, s_n) + T(1 - s_1, \dots, 1 - s_n)} \quad (2)$$

$$T(s_1, s_2, \dots, s_n) = \prod_{i=1}^n s_i \quad (3)$$

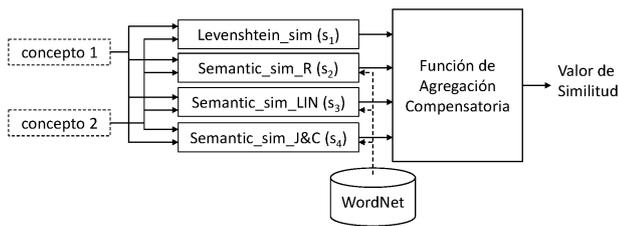


Fig. 2. Flujo de trabajo para la evaluación de la similitud entre conceptos.

En la integración de información entre dos grafos  $G_1$  y  $G_2$  se define un umbral  $U$ , que representa el valor mínimo de similitud existente entre dos nodos-conceptos para ser integrados. Cada nodo del grafo puede agrupar uno o varios conceptos en dependencia de las integraciones anteriores. En este proceso, se mide la similitud entre cada nodo  $N_i$  de  $G_1$  y todos los nodos de  $G_2$  y luego se integran aquellos nodos que tengan una similitud igual o superior a  $U$ . Este proceso se ejecuta iterativamente hasta que se compare el último nodo  $N_i$  con todos los nodos de  $G_2$ . La ecuación (4) describe el cálculo de la similitud entre dos nodos  $N$  y  $M$ , donde  $N$  está formada por el conjunto de conceptos  $\{cn_1, cn_2, \dots, cn_n\}$  y  $M$  por otro conjunto de conceptos  $\{cm_1, cm_2, \dots, cm_m\}$ . Donde  $simSD$  es la función de agregación descrita anteriormente y  $ln$  y  $lm$  las cantidades de conceptos en los nodos  $N$  y  $M$ . Los nodos con etiqueta  $l_r$ , representan el primer concepto del grupo y estos conceptos se representan a su vez por conceptos separados por una coma y encerrados entre [ ] (ej.  $[c_1, c_2]$ ).

$$sim(N, M) = \frac{\sum_{i=1}^n \sum_{j=1}^m simSD(cn_i, cm_j)}{ln * lm} \quad (4)$$

Los conceptos representados en un mismo nodo se consideran que tienen una fuerte relación de sinonimia y por tanto, de esa manera son tratados en el modelo de recuperación concebido como parte de las consultas de *Proyección* ( $Q$ ). En este tipo de consultas el usuario especifica uno o varios conceptos de interés ( $CQ$ ), y selecciona un conjunto de grafos del RGC para formar el espacio de

búsqueda ( $G_D$ ). Se definieron varias reglas para identificar si un nodo  $n_j / n_j \in N^{Gd}$  es recuperado o no, a partir del concepto  $c_i \in CQ$ . Estas reglas son ejecutadas en el mismo orden en que aparecen. Siendo, los conceptos  $a / a \in CQ$ , y  $b / b \in N^{Gd}$ ,  $T(c_i)$  el conjunto de palabras que conforman  $c_i$ ,  $l_r(b)$  la etiqueta representativa del nodo  $n_j$  y  $ST(n_i)$  el grupo de conceptos de  $n_i$ . El nodo  $b$  es recuperado si: ( $R_1$ )  $a \equiv l_r(b)$  (sintácticamente); o ( $R_2$ )  $a \in T(l_r(b))$ ; o ( $R_3$ )  $a \in ST(b)$ . Este tipo de consultas requiere que el usuario conozca los  $CQ$  que serán objeto de análisis. En tal sentido, se incorpora al modelo un mecanismo de identificación y recomendación de conceptos relevantes, el cual se describe a continuación.

### 3) Identificación y Recomendación de conceptos

En este proceso se obtiene un ranking de los  $k$  conceptos más relevantes de la colección de textos, teniendo en cuenta como criterios: frecuencia de aparición de los conceptos en los textos y la relevancia de los conceptos en el grafo que representa el contenido de la colección de textos. La frecuencia de aparición de los conceptos se computa en el mismo proceso de integración de los grafos generados que se ejecuta como parte de la *Unión*, a partir de esta consulta se extraen y ordenan los  $k$  conceptos más frecuentes de forma descendente para ser mostrados al usuario. La identificación de conceptos relevantes de acuerdo al segundo criterio se lleva a cabo mediante la aplicación del algoritmo PageRank [6] sobre el grafo resultante de la operación de *Unión*, en el cual está representada la conceptualización de la colección de textos. De la misma forma, como resultado se muestra al usuario de forma ordenada descendente los  $k$  conceptos con mayor valor de relevancia, según el PageRank. Esta funcionalidad potencia el uso de las consultas de *Proyección*, ya que el resultado de estos procesos sirve de guía al usuario en cuanto al análisis de los textos sobre la base de disponer de información sobre los conceptos más relevantes y representativos de la colección.

### C. Recuperación de Pasajes

La inclusión de este proceso tiene el objetivo de ofrecer al usuario la posibilidad de recuperar fragmentos de textos de las fuentes primarias de información, a partir de conceptos representados en el grafo resultante de las consultas definidas para el análisis de los grafos, mediante el uso de Lucene. La forma en que se utiliza la recuperación de pasajes en este trabajo también puede considerarse como un tipo de análisis de grafos, pues se está analizando el grafo con respecto a los textos. En este caso, las consultas se construyen a partir de la selección por el usuario, de conceptos y/o proposiciones de interés representados en el grafo y se utiliza el conjunto de conceptos agrupados en un mismo nodo del grafo, para ejecutar un proceso de expansión de las consultas. Además, se emplea el operador *OR* para los conceptos de la consulta y *AND* para las proposiciones. La construcción de los pasajes se lleva a cabo a partir de la identificación de oraciones centrales en el Índice de Textos, las cuales pueden ser expandidas según el tamaño del pasaje ( $PS$ ) especificado por el usuario. La oración central constituye la oración en la que aparecen los conceptos incluidos en la consulta, según el operador utilizado.  $PS$  se define como la cantidad máxima de oraciones que conforma el pasaje, y como este valor numérico puede ser par o impar, se



definieron reglas para determinar la cantidad real de oraciones (adyacentes a la oración central) a ser incluidas en el pasaje: (R1) Si  $PS = 1$  entonces se devuelve la oración central; (R2) Si  $PS$  es par entonces se incluyen las  $PS/2$  oraciones anteriores a la oración central y las  $(PS/2)-1$  oraciones contiguas; y (R3) Si  $PS$  es impar entonces se incluyen  $PS/2$  oraciones anteriores y contiguas a la oración central. Como resultado, por cada concepto y/o proposición, se muestran los pasajes de texto recuperados, los identificadores de los textos fuentes y la cantidad de pasajes recuperados por cada uno, resaltando los conceptos incluidos en la consulta.

#### IV. EVALUACIÓN DEL MODELO PROPUESTO: CASO DE ESTUDIO

La evaluación experimental de esta propuesta resulta compleja debido, fundamentalmente, a la ausencia de métodos y colecciones de evaluación estandarizados para este tipo de soluciones, en especial para la representación del texto [10], de la cual depende en gran medida el resto de los procesos. La evaluación de la recuperación de información suele enfocarse en la medición de resultados a partir de los documentos recuperados dado una consulta, y no a estructuras conceptuales incluidas en ellos, como se pretende con esta propuesta. En este sentido, se decidió aplicar un enfoque de evaluación similar a [12], en el contexto de las SLR.

La SLR es un medio de identificación, interpretación y evaluación de la evidencia científica relevante sobre una pregunta de investigación, tópico o fenómeno de interés [15]. Muchas de las tareas de la SLR, como la extracción y síntesis de datos, requieren alto consumo de tiempo, y mucho trabajo manual, implicando un gran esfuerzo [3]. En la extracción de datos se extraen de cada uno de los estudios un conjunto de datos (ej. bibliográficos, cuantitativos y cualitativos) que se definen en la fase de planificación en forma de un formulario. En la síntesis se combinan estos datos para darle respuesta a las preguntas de investigación iniciales. Este caso de estudio se enfoca en las tareas de extracción y síntesis de datos de la SLR reportada en [8], donde se analizan 11 artículos científicos. El objetivo del caso de estudio es ejemplificar la aplicabilidad del modelo propuesto para las tareas mencionadas. A partir de esos artículos, se conformaron 11 textos, con 822 palabras y 33 oraciones cada uno (como promedio) usando las secciones de resumen, introducción y conclusiones de cada artículo. Según la propuesta, inicialmente se indexan los textos y se generan los grafos a partir de ellos, constituyéndose el Índice y el RGC.

El modelo propuesto permite soportar y combinar la extracción y síntesis de datos mediante la utilización y combinación de sus principales procesos. La aplicación de la consulta de intersección (*Inter*) (similar a [12]) y el uso de la recomendación de conceptos, obtienen los conceptos que tienen una frecuencia igual o superior al *SV* en la colección de textos y las relaciones entre ellos representadas en los grafos. Estos conceptos pueden considerarse palabras claves o terminología que caracteriza ese contenido, y permitan responder a las preguntas de investigación. En la Fig. 3 se ejemplifica el resultado de la consulta *Inter*<sup>50</sup>(RGC), donde el tamaño de los nodos representa el nivel de frecuencia de los conceptos. En esta Fig. se identifican [software], [dependability, reliability] e [ISO] como conceptos más

relevantes, lo que se corrobora con el título del artículo [8], donde tres de ellos aparecen. En este ejemplo, también se ilustran resultados del análisis semántico difuso en la unificación de 'dependability' y 'reliability', lo cual contribuye a conocer rápidamente la terminología usada para referirse al mismo concepto. La relación 'strong relation' indica que los conceptos [software] e [ISO] tienen una fuerte relación contextual, sugiriendo un análisis adicional, que puede soportarse con el uso de la *Proyección* y/o la recuperación de pasajes. El uso de la recuperación de pasajes en este trabajo brinda, a diferencia de las otras propuestas, la posibilidad de conocer en que fuentes se encuentran los conceptos y su contexto, permitiendo extraer datos que se requieran para llenar los formularios de los estudios, y así poder registrar esta información. Además, de las etiquetas de los campos del formulario pueden obtenerse conceptos de referencia que sirvan de base al modelo para obtener información, principalmente cualitativa, que sirva tanto para la extracción como para la síntesis de datos.

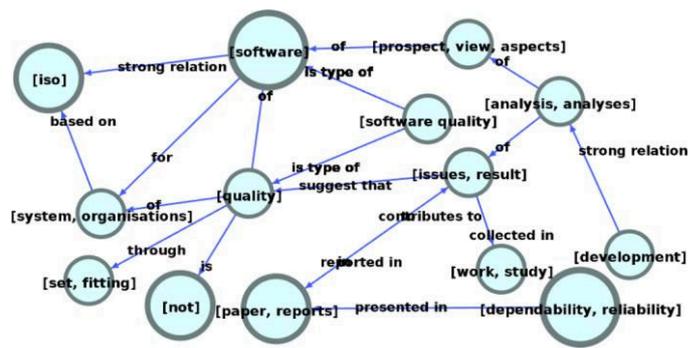


Fig. 3. Resultado de la consulta *Inter*<sup>50</sup>(RGC).

Al tener identificados conceptos de interés se puede aplicar la consulta de *Proyección*, así como la recuperación de pasajes para profundizar en el análisis de los mimos. En este caso, se ejecutó esta consulta usando el RGC como espacio de búsqueda y 'standard' como concepto de interés (*Proj*<sup>1</sup>(RGC, standard)), respondiendo a la pregunta: "Which software reliability models have been developed by following the recommendations in International Standards?" [8], donde 'standard' es uno de los términos relevantes. El resultado se muestra en la Fig. 4, donde se representan varios conceptos relacionados con 'standard' y asociados a 'International Standards', tales como: ISO, IEEE, SQuaRE, y COSMIC. En la Fig. 4 se representan también conceptos presentes en diferentes fuentes textuales, lo cual es posible a partir del análisis semántico difuso concebido. Este análisis se complementó con la recuperación de los pasajes, donde aparecen algunos de los conceptos representados en la Fig. 4 (se muestra en la misma figura), y puede ser utilizado en la extracción de datos para conocer en estudios aparecen los distintos estándares. Los resultados expuestos reflejan beneficios de la propuesta como soporte a las SLR para las tareas de extracción y síntesis de datos a partir del análisis del contexto en el que están siendo usados los conceptos, la obtención de vistas resumidas y sintetizadas del contenido, que facilitan el análisis cualitativo y cuantitativo sobre los conceptos, entre otros aspectos.





# Definición de particiones difusas condicionadas usando transformadas difusas.

Nicolás Madrid  
 Departamento de Matemática Aplicada  
 Universidad de Málaga  
 Málaga, España  
 nicolas.madrid@uma.es

Sergio Díaz-Gómez  
 Universidad de Málaga  
 Málaga, España  
 sergiodg96@hotmail.com

**Abstract**—Las particiones difusas pueden definirse de diferentes formas, pero casi siempre, la definición se efectúa atendiendo a las características generales de la totalidad del universo. En este trabajo se presenta un método para definir particiones difusas condicionadas a la satisfacción de cierto atributo difuso. En concreto, se muestra cómo definir diferentes particiones difusas atendiendo a las características de diferentes subconjuntos difusos del universo.

## I. INTRODUCTION

Todo sistema difuso consta de tres partes bien conocidas: *fuzzificación*, *inferencia* y *defuzzificación*. En muchos casos, estos tres pasos se apoyan en uno de los conceptos más importantes del paradigma de los sistemas difusos: la partición difusa.

Aunque la definición de partición difusa difiere según diferentes autores (ver [2], [4], [5], [10]), en general la idea es dividir al universo de discurso en una serie de clases difusas (normalmente asociados a etiquetas lingüísticas). Existen multitud de formas de definir particiones difusas sobre un universo  $\mathcal{U}$ . La más conocida, que no necesariamente la más conveniente, es la familia de particiones dadas por expertos. Éste tipo de particiones es útil cuando la partición viene dada por conceptos lingüísticos propios del ser humano sin sustento científico ni definición formal; como pueden ser la división del día en intervalos de tiempo vagos como la mañana, tarde, noche, etc; la división de vegetales en fruta o verdura; o la clasificación de animales en mascotas.

Otra familia de particiones difusas muy utilizada es la constituida por las particiones uniformes. Éstas dividen el universo de manera homogénea en espacio y forma. A pesar de su simplicidad, han mostrado ser de gran utilidad para muchas tareas, como puede comprobarse en el área de procesamiento de imágenes [9].

Con el fin de definir particiones difusas óptimas para ciertas tareas, se han definido algoritmos automatizados para el cálculo de particiones basados en clustering y/o estadística [10], [3]. Sin entrar en detalles, estos algoritmos consideran uno o varios atributos de los elementos del universo y calculan parámetros de referencia (clusters o parámetros estadísticos) que se utilizan para la definición de las clases que definirán la partición. Como ejemplo, las particiones basadas

en clustering han mostrado ser útiles para la obtención de reglas difusas [1], [6].

Independientemente de cómo se defina la partición, es obvio que ésta depende de un contexto. Supongamos que deseamos tener una partición difusa del atributo altura para personas. En este caso, la clase de *personas altas*, que podría ser una clase de dicha partición difusa, depende claramente del contexto: no es lo mismo una persona alta en una liga de baloncesto, en un campeonato de hípica o en un colegio de primaria. En la mayoría de los casos, este contexto está implícito en la tarea a resolver y, aunque no se mencione, se considera en la definición de la partición. Por ejemplo, si el sistema difuso se plantea para clasificar alumnos con sobrepeso de un colegio de primaria, de nada sirve considerar el concepto de altura que pueda derivarse de un contexto de liga profesional de baloncesto.

En este trabajo proponemos posibilitar el uso de diferentes particiones difusas dependiendo del contexto. Siguiendo el ejemplo anterior, si queremos un sistema difuso para clasificar personas con sobrepeso, sería interesante disponer de multitud de particiones difusas acorde al contexto al que dicha persona pertenezca. Así, el sistema utilizaría una partición diferente si la persona es un alumno de primaria, un jugador profesional de baloncesto o un jinete de la carrera Sanlúcar. Cuando el contexto viene dado por una serie de conjuntos crisp, la definición de dichas particiones se reduce al caso clásico. Sin embargo, cuando los conjuntos que definen los diferentes contextos son también difusos, la definición de dichas particiones difusas no es una tarea trivial. Siguiendo el ejemplo, podríamos estar interesados en definir un sistema difuso para detectar sobrepeso en personas con ingresos medios.

En este trabajo presentamos un método para definir particiones difusas para aquellos elementos del universo que tengan cierta propiedad difusa. Dicha partición se definirá mediante el uso de transformadas difusas [8], [7], que pueden entenderse como medias ponderadas por conjuntos difusos. En pos de una mejor comprensión de la metodología, se presenta cómo se definen cinco particiones difusas de un conjunto de muestras de generación energética acorde al momento del día en el que fueron tomadas; i.e., durante la madrugada, la mañana, el mediodía, la tarde o la noche.

El trabajo está estructurado de la siguiente manera. Comen-

zamos presentando ciertos conceptos básicos en la Sección II. En la Sección III presentamos como se definen las F-transformadas directa e inversa. En la Sección IV mostramos cómo definir particiones difusas de tres clases para los elementos del universo que tengan cierto atributo difuso. En esta sección mostraremos además cómo se aplica la metodología al caso de la generación eléctrica condicionada al tramo horario. Finalmente, en la Sección V presentamos las conclusiones y el trabajo futuro.

## II. PRELIMINARIES

El concepto de partición difusa se define de manera general de la siguiente forma.

*Definición 1:* Una partición difusa  $\Delta$  de un universo  $\mathcal{U}$  es un conjunto  $\{\Delta_1, \dots, \Delta_n\}$  de conjuntos difusos sobre  $\mathcal{U}$  que cumplen la condición de recubrimiento, es decir, para todo  $x \in \mathcal{U}$  existe  $k \in \{1, \dots, n\}$  tal que  $\Delta_k(x) > 0$ .

En la bibliografía se pueden encontrar una gran cantidad de propiedades adicionales que se imponen sobre las particiones difusas. A continuación enumeramos una serie de propiedades que cumplirán las particiones definidas en este trabajo. Una partición  $\Delta = \{\Delta_1, \dots, \Delta_n\}$  sobre  $[0, 1]$  se define a partir de ciertos nodos  $0 = x_1 < x_2 < \dots < x_n = 1$  tales que:

- (normalidad)  $\Delta_k(x_k) = 1$ .
- (soporte acotado)  $\Delta_k(x) = 0$  si  $x \notin (x_{k-1}, x_{k+1})$ .
- (continuidad)  $\Delta_k(x)$  es continua.
- (convexidad)
  - $\Delta_k(x)$  es estrictamente creciente en  $(x_{k-1}, x_k)$  y
  - $\Delta_k(x)$  es estrictamente decreciente en  $(x_k, x_{k+1})$ .
- (Ruspini) para todo  $x \in [0, 1]$ :

$$\sum_{k=1}^n \Delta_k(x) = 1$$

Las funciones de pertenencia de los conjuntos difusos que forman las particiones difusas pueden darse de infinidad de maneras. Por practicidad, suelen elegirse funciones de pertenencia sencillas que se definen a partir de ciertos parámetros. En este trabajo vamos a considerar funciones de pertenencia triangulares y trapezoidales, que se definen sobre el universo de los números reales a partir de tres/cuatro parámetros  $a, b, c, d \in \mathbb{R}$  de la siguiente forma:

$$\text{triangular}(a, b, c)(x) = \begin{cases} 0 & \text{si } x \leq a \\ \frac{x-a}{b-a} & \text{si } a < x \leq b \\ \frac{b-x}{b-c} & \text{si } b < x \leq c \\ 0 & \text{si } c < x \end{cases}$$

$$\text{trapezoidal}(a, b, c, d)(x) = \begin{cases} 0 & \text{si } x \leq a \\ \frac{x-a}{b-a} & \text{si } a < x \leq b \\ 1 & \text{si } b < x \leq c \\ \frac{d-x}{d-c} & \text{si } c < x \leq d \\ 0 & \text{si } d < x \end{cases}$$

En algunos casos haremos un pequeño abuso de notación aceptando, en el caso de las funciones de pertenencia trapezoidales, que los parámetros  $a, b$  y  $c, d$  puedan ser  $-\infty$  o  $\infty$ ,

respectivamente. En dichos casos, las funciones de pertenencia refieren a

$$\text{trapezoidal}(-\infty, -\infty, c, d)(x) = \begin{cases} 1 & \text{si } x \leq c \\ \frac{d-x}{d-c} & \text{si } c < x \leq d \\ 0 & \text{si } d < x \end{cases}$$

y

$$\text{trapezoidal}(a, b, \infty, \infty)(x) = \begin{cases} 0 & \text{si } x \leq a \\ \frac{x-a}{b-a} & \text{si } a < x \leq b \\ 1 & \text{si } b < x \end{cases}$$

En general, existen multitud de formas de definir particiones difusas en un cierto universo  $\mathcal{U}$ , aunque éstas se pueden clasificar en dos familias: particiones basadas puramente en etiquetas lingüísticas dadas por un experto y particiones definidas a partir de herramientas de clustering o parámetros estadísticos (con o sin supervisión). En el Ejemplo 1 se describe una partición dada por un experto concerniente a los intervalos temporales de un día.

*Ejemplo 1:* El ser humano suele dividir las 24 horas del día en los siguientes cinco intervalos temporales: *madrugada*, *mañana*, *mediodía*, *tarde* y *noche*. Dichos intervalos se pueden modelar como cinco conjuntos difusos trapezoidales de la siguiente manera:

Madrugada = trapezoidal (00, 02, 05, 07)

Mañana = trapezoidal (05, 07, 11, 13)

Mediodía = trapezoidal (11, 13, 14, 15)

Tarde = trapezoidal (14, 15, 18, 20)

Noche = trapezoidal (18, 20, 23, 01)

donde el tiempo viene dado en horas con notación 24h. Las gráficas de los cinco conjuntos difusos que forman esta partición vienen dadas en la Figura 1. Obsérvese que dicha partición satisfacen todas las propiedades adicionales de normalidad, soporte acotado, continuidad, convexidad y Ruspini.  $\square$

Puesto que este trabajo está orientado en el uso de parámetros estadísticos para la definición de particiones difusas, vamos a esbozar a continuación un sencillo algoritmo para definir una posible partición difusa de tres clases a partir de la información de un atributo difuso  $X$ ; es decir, un conjunto difuso  $X: \mathcal{U} \rightarrow [0, 1]$ . Las tres clases van a representar las etiquetas lingüísticas “atributo  $X$  bajo”, “atributo  $X$  medio” y “atributo  $X$  alto”. Uno de los valores más representativos, si no el que más, de lo que sería un valor “medio” del atributo  $X$  sería la *media* del conjunto de valores  $\{X(u)\}_{u \in \mathcal{U}}$ . De este modo, cuanto más cerca esté el atributo  $X$  de la media, más “medio” será. Modelar este concepto de cercanía se puede hacer a través de múltiples expresiones y un punto clave es determinar qué valores del atributo  $X$  dejan de clasificarse como “medios”. Quizás la forma más natural para hacer esto último es mediante el cálculo de una medida de dispersión sobre el conjunto de valores  $\{X(u)\}_{u \in \mathcal{U}}$ , que determinaría un intervalo para los valores “medios”.

*Ejemplo 2:* Supongamos que queremos realizar una partición sobre los números reales (i.e.,  $\mathcal{U} = \mathbb{R}$ ) acorde a cierto atributo  $X: \mathbb{R} \rightarrow [0, 1]$ . Supongamos que la media y la

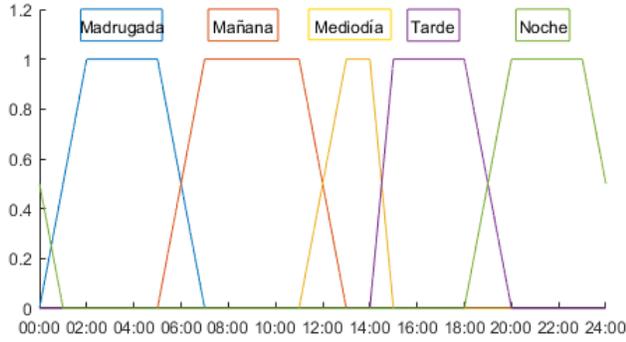


Figure 1. Partición difusa para el día dada por un experto acorde a las etiquetas lingüísticas *madrugada*, *mañana*, *mediodía*, *tarde* y *noche*.

desviación típica de  $\{X(u)\}_{u \in \mathbb{R}}$  son  $\mu$  y  $\sigma$ , respectivamente. Entonces, la partición difusa formada por las siguientes tres clases:

$$\Delta_1 = \text{trapezoidal}(-\infty, -\infty, \mu - \sigma, \mu)$$

$$\Delta_2 = \text{triangular}(\mu - \sigma, \mu, \mu + \sigma)$$

$$\Delta_3 = \text{trapezoidal}(\mu, \mu + \sigma, \infty, \infty)$$

modeliza los conceptos “*atributo X bajo*”, “*atributo X medio*” y “*atributo X alto*”, respectivamente.

Merece la pena mencionar la existencia de otros métodos para definir particiones difusas basados en cuartiles o clústering [4], [10].

### III. TRANSFORMADAS DIFUSAS

Las transformadas difusas fueron aplicadas en su origen sobre funciones definidas entre el intervalo unidad [8] y recientemente extendidas para ser aplicadas a un conjunto de puntos arbitrario del producto cartesiano  $\mathcal{U} \times [0, 1]$  para  $\mathcal{U}$  un conjunto arbitrario [7].

Las transformadas discretas para datos sin estructura funcional se definen de la siguiente manera.

**Definición 2:** Dado  $\mathbf{T} = \{(x_i, y_i)\}_{i \in \mathbb{I}} \subseteq \mathcal{U} \times [0, 1]$  y una partición difusa  $\Delta = \{\Delta_1, \dots, \Delta_n\}$  de  $\mathcal{U}$ , decimos que la  $n$ -tupla  $\mathbf{F}_\Delta[\mathbf{T}] = [F_1, \dots, F_n] \in [0, 1]^n$  es la F-transformada directa de  $\mathbf{T}$  con respecto a  $\Delta$  si se cumple la igualdad

$$F_k = \frac{\sum_{i \in \mathbb{I}} y_i \Delta_k(x_i)}{\sum_{i \in \mathbb{I}} \Delta_k(x_i)} \quad (1)$$

No es difícil comprobar que la definición anterior extiende a la original [8] dada en el contexto de funciones, identificando la función  $f: \mathcal{U} \rightarrow [0, 1]$  con el subconjunto  $\mathbf{T}_f = \{(x, f(x)) \mid x \in \mathcal{U}\} \subseteq \mathcal{U} \times [0, 1]$ , i.e.,  $\mathbf{F}_\Delta[\mathbf{T}_f] = \mathbf{F}_\Delta[f]$ . El siguiente resultado muestra que las componentes de la F-transformada directa coinciden con la solución de un problema de *mínimos cuadrados* ponderado por las funciones de la partición  $\Delta$ .

**Proposición 1:** Dado  $\mathbf{T} = \{(x_i, y_i)\}_{i \in \mathbb{I}} \subseteq \mathcal{U} \times [0, 1]$  y una partición difusa  $\Delta = \{\Delta_1, \dots, \Delta_n\}$  de  $\mathcal{U}$ , la  $k$ -ésima componente de la F-transformada coincide con el mínimo de la función

$$\phi(z) = \sum_{i \in \mathbb{I}} (y_i - z)^2 \Delta_k(x_i) \quad (2)$$

A partir de la F-transformada directa, podemos definir la F-transformada inversa como se muestra a continuación.

**Definición 3:** Dado  $\mathbf{T} = \{(x_i, y_i)\}_{i \in \mathbb{I}} \subseteq \mathcal{U} \times [0, 1]$  y su F-transformada directa  $\mathbf{F}_\Delta[\mathbf{T}] = [F_1, \dots, F_n] \in [0, 1]^n$  con respecto a  $\Delta$  se define la F-transformada inversa de  $\mathbf{T}$  con respecto a  $\Delta$  como la función:

$$\mathbf{T}_\Delta^F(x) = \frac{\sum_{k=1}^n F_k \Delta_k(x)}{\sum_{k=1}^n \Delta_k(x)}. \quad (3)$$

Antes de proseguir, vamos a comentar algunos aspectos de la definición anterior. La F-transformada inversa es una función de  $\mathcal{U}$  a  $[0, 1]$  independientemente de si  $\mathbf{T}$  tiene estructura de función o no (i.e., tiene estructura de función si para todo  $u \in \mathcal{U}$  existe  $x \in [0, 1]$  tal que  $(u, x) \in \mathbf{T}$  y si además tenemos que dos tuplas  $(u, x)$  y  $(u, y)$  pertenecen a  $\mathbf{T}$ , entonces  $x = y$ ). En segundo lugar, el dominio de la F-transformada inversa es todo  $\mathcal{U}$  independientemente de si para cierto  $u \in \mathcal{U}$  existen o no valores tales que  $(u, y) \in \mathbf{T}$ . Finalmente, como se muestra en el siguiente teorema (Teorema 1), la transformada inversa está estrechamente relacionada con la función que asigna a cada  $u \in \mathcal{U}$  el valor medio de los valores  $x_i \in [0, 1]$  tales que  $(u, x_i) \in \mathbf{T}$ . Formalmente, definimos los conjuntos

$$D_u = \{x \in [0, 1] \mid (u, x) \in \mathbf{T}\} \quad \text{para cada } u \in \mathcal{U} \quad (4)$$

y

$$D_{\mathbf{T}} = \{u \in \mathcal{U} \mid \text{tal que existe } (u, x) \in \mathbf{T}\} \quad (5)$$

Sobre el dominio  $D_{\mathbf{T}}$  definimos la función  $m_{\mathbf{T}}(u)$  que asigna a cada  $u \in D_{\mathbf{T}}$  el valor

$$m_{\mathbf{T}}(u) = \frac{\sum_{x_i \in D_u} x_i}{|D_u|} \quad (6)$$

donde  $|D_u|$  denota la cardinalidad del conjunto  $D_u$ . Observe que  $m_{\mathbf{T}}$  es la función que asigna a cada  $u \in \mathcal{U}$  la media de todos los valores  $x_i$  tales que  $(u, x_i) \in \mathbf{T}$ .

**Teorema 1:** Para todo  $\mathbf{T} = \{(u_i, x_i)\}_{i \in \mathbb{I}} \subseteq \mathcal{U} \times [0, 1]$  existe una partición difusa  $\Delta$  tal que

$$\mathbf{T}_\Delta^F(u) = m_{\mathbf{T}}(u),$$

donde  $m_{\mathbf{T}}$  es la función definida en la Ecuación (6).

A partir del teorema anterior, podemos decir que la F-transformada inversa aproxima en cierto modo la función  $m_{\mathbf{T}}$  que asigna a cada  $u \in \mathcal{U}$  el valor medio de los valores  $x_i \in [0, 1]$  tales que  $(u, x_i) \in \mathbf{T}$ .

### IV. DEFINIENDO PARTICIONES CONDICIONADAS

#### A. Descripción del procedimiento

Vamos a considerar un universo  $\mathcal{U}$  junto con dos atributos  $X$  y  $Y$  que poseen los elementos de  $\mathcal{U}$ . En la Sección II hemos visto cómo definir particiones difusas de  $\mathcal{U}$  basándonos en la información de uno de los atributos  $X$  o  $Y$ . En esta sección vamos a presentar un método para definir una partición difusa en  $\mathcal{U}$  basándonos en un atributo  $Y$  condicionado a la información que tenemos sobre otro atributo  $X$ . Por simplicidad en la exposición, vamos a definir particiones difusas con tres

clases, aunque el método puede extenderse fácilmente para el cálculo de particiones difusas con más clases.

Comenzamos asumiendo una partición difusa  $\Delta$  de  $\mathcal{U}$  acorde a los valores que toma el atributo  $X$ . Entonces, la coordenada  $F_k$  de la F-transformada directa de  $\mathbf{T}_X = \{(u_i, Y(u_i))\}_{i \in \mathbb{I}} \subseteq \mathcal{U} \times [0, 1]$  con respecto a  $\Delta$  puede considerarse como la media del atributo  $Y$  para aquellos elementos de  $\mathcal{U}$  que tienen el atributo  $X$  en  $\Delta_k$ . De este modo, si queremos hacer una partición de tres clases para los elementos de  $\mathcal{U}$  que tengan el atributo  $X$  en  $\Delta_k$ ,  $F_k$  es sin duda un buen candidato para ser el núcleo de la clase central, que representa los elementos con atributo  $Y$  medio. Para representar el resto de los valores del atributo  $Y$  que pueden considerarse “medios”, vamos a establecer una estimación, en forma de intervalo, para la dispersión de los datos a partir de la media ponderada dada por  $F_k$ . Los límites de dicho intervalo van a consistir en el cálculo de otras dos F-transformadas directas, una para los valores del atributo  $Y$  que tienen valores superiores a la media  $F_k$ , y otro para los valores inferiores. La interpretación de este intervalo es similar al del rango intercuartílico pero a través de expectiles, en lugar de cuartiles.

Para ser más específicos, el procedimiento que se lleva a cabo para la definición de la partición condicionada es el siguiente:

- 1) Calculamos la F-transformada directa de

$$\mathbf{T}_Y = \{(u_i, Y(u_i))\}_{i \in \mathbb{I}}$$

con respecto a una partición difusa  $\Delta_X$  definida acorde al atributo  $X$ ;

- 2) Calculamos la F-transformada inversa  $(\mathbf{T}_Y)_{\Delta}^F(x)$  de  $\mathbf{T}_Y = \{(u_i, Y(u_i))\}_{i \in \mathbb{I}}$  con respecto a  $\Delta_X$ ;
- 3) Definimos los siguiente dos conjuntos:

$$\mathbf{T}_Y^{\uparrow} = \{(u_i, Y(u_i)) \mid Y(u_i) \geq (\mathbf{T}_Y)_{\Delta}^F(u_i)\}_{i \in \mathbb{I}}$$

$$\mathbf{T}_Y^{\downarrow} = \{(u_i, Y(u_i)) \mid Y(u_i) \leq (\mathbf{T}_Y)_{\Delta}^F(u_i)\}_{i \in \mathbb{I}}$$

- 4) Calculamos las F-transformadas directas

$$F_{\Delta_X}[\mathbf{T}_Y^{\uparrow}] \quad \text{y} \quad F_{\Delta_X}[\mathbf{T}_Y^{\downarrow}]$$

de los conjuntos  $\mathbf{T}_Y^{\uparrow}$  y  $\mathbf{T}_Y^{\downarrow}$  respectivamente;

- 5) En pos de una presentación más eficiente, vamos a denotar por

- $F_k^{\uparrow}$  a la coordenada  $F_k$  en  $F_{\Delta_X}[\mathbf{T}_Y^{\uparrow}]$ ;
- $F_k^{\downarrow}$  a la coordenada  $F_k$  en  $F_{\Delta_X}[\mathbf{T}_Y^{\downarrow}]$ ;
- $F_k^*$  a la coordenada  $F_k$  en  $F_{\Delta_X}[\mathbf{T}_Y]$ ;

Para cada  $(\Delta_X)_k$ , definimos la partición difusa  $\Delta_Y \mid X_k$  definida por los siguiente tres conjuntos difusos:

$$\Delta_1 = \text{trapezoidal}(-\infty, -\infty, F_k^{\downarrow}, F_k^*)$$

$$\Delta_2 = \text{triangular}(F_k^{\downarrow}, F_k^*, F_k^{\uparrow})$$

$$\Delta_3 = \text{trapezoidal}(F_k^*, F_k^{\uparrow}, \infty, \infty).$$

### B. Ejemplo: generación de energía

Para mostrar el procedimiento de una forma clara, vamos a definir particiones difusas para la producción de energía condicionadas al momento del día al que dicha energía es generada. Para ello, utilizaremos la división temporal descrita

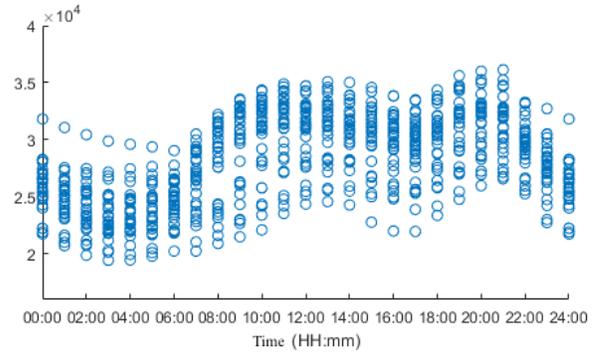


Figure 2. Nube de puntos de la energía generada en la zona peninsular de España durante enero del 2018.

en el Ejemplo 1 para el día; a saber, en *madrugada*, *mañana*, *mediodía*, *tarde* y *noche*. El objetivo es, por lo tanto, definir cinco particiones difusas acorde a la generación de energía teniendo en cuenta de si ésta se ha producido durante la *madrugada*, *mañana*, *mediodía*, *tarde* o *noche*.

Para llevar a cabo el ejemplo haremos uso de los datos disponibles en la página web del Ministerio de Energía, Turismo y Agenda Digital ([www.minetad.gob.es](http://www.minetad.gob.es)) para la generación de energía en la zona peninsular de España durante el mes de enero del 2018. La generación viene dada por intervalos de una hora y la nube de puntos asociada a dicha base de datos viene dada en la Figura 2.

Los componentes de la F-transformada directa  $F_{\Delta}[\mathbf{T}]$  son:

$$\begin{aligned} F_1 &= 23891 \text{ MWh} & F_2 &= 28802 \text{ MWh} \\ F_3 &= 30826 \text{ MWh} & F_4 &= 29877 \text{ MWh} \\ F_5 &= 29391 \text{ MWh} \end{aligned}$$

Como ejemplo, para una interpretación más clara de los resultados obtenidos, el valor  $F_2 = 28802 \text{ MWh}$  representa la media de la generación de energía durante *las mañanas* de enero del 2018. La correspondiente F-transformada inversa está dibujada en la Figura 3 junto con la subdivisión de los datos en dos clases: aquellos con valores superiores (azules en la figura y denotados por  $\mathbf{T}^{\uparrow}$ ) e inferiores (rojos en la figura y denotados por  $\mathbf{T}^{\downarrow}$ ) a la media dada por  $F_{\Delta}[\mathbf{T}]$ , respectivamente.

Al calcular las correspondientes F-transformadas directas de  $\mathbf{T}^{\uparrow}$  y de  $\mathbf{T}^{\downarrow}$  obtenemos las componentes:

$$\begin{aligned} F_1^{\uparrow} &= 25834 \text{ MWh} & F_2^{\uparrow} &= 31468 \text{ MWh} \\ F_3^{\uparrow} &= 32550 \text{ MWh} & F_4^{\uparrow} &= 31804 \text{ MWh} \\ F_5^{\uparrow} &= 32105 \text{ MWh} \end{aligned}$$

y

$$\begin{aligned} F_1^{\downarrow} &= 22411 \text{ MWh} & F_2^{\downarrow} &= 25027 \text{ MWh} \\ F_3^{\downarrow} &= 27863 \text{ MWh} & F_4^{\downarrow} &= 27129 \text{ MWh} \\ F_5^{\downarrow} &= 26754 \text{ MWh} \end{aligned}$$

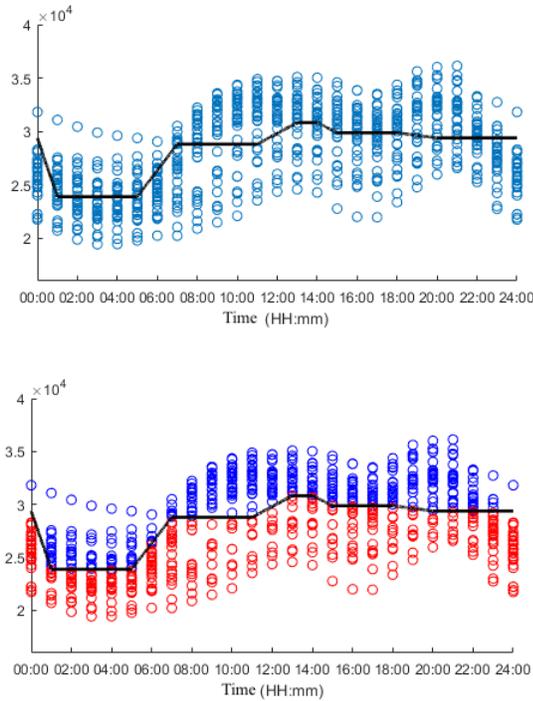


Figure 3. Transformada inversa de los datos de generación eléctrica junto con los dos conjuntos de datos  $T^\uparrow$  (azul) y  $T^\downarrow$  (rojo).

Las dos F-transformadas directas dadas justo arriba tienen una interpretación muy similar al rango intercuartílico pero en términos de expectativas. Específicamente, puesto que  $T^\uparrow$  y  $T^\downarrow$  representan las medias de los datos por encima y por debajo de la F-transformada inversa, que a su vez representa una media, es esperable que la mitad de los datos se encuentren entre  $T^\uparrow$  y  $T^\downarrow$ . En concreto, en este ejemplo, podemos decir que esperamos que en la mayoría de las mañanas ( $\Delta_2$ ), la generación eléctrica se encuentre entre  $F_2^\downarrow = 25027 \text{ MWh}$  y  $F_2^\uparrow = 31468 \text{ MWh}$ . Siguiendo esta línea, durante las mañanas podemos atribuir a los valores de la generación eléctrica menores a  $25027 \text{ MWh}$  (resp. mayores a  $31468 \text{ MWh}$ ) la etiqueta de *generación eléctrica baja* (resp. *generación eléctrica alta*). Tenemos, por lo tanto, cinco particiones difusas, una para cada conjunto de la partición  $\Delta$ , en la que podemos establecer cuándo la generación eléctrica es alta, media o baja, condicionado al momento del día en que se esté considerando: *madrugada*, *mañana*, *mediodía*, *tarde* o *noche*. Dichas particiones vienen dadas como sigue:

Madrugadas:

- $\Delta_1 = \text{trapezoidal } (-\infty, -\infty, 22411, 23891)$
- $\Delta_2 = \text{triangular } (22411, 23891, 25834)$
- $\Delta_3 = \text{trapezoidal } (23891, 25834, \infty, \infty)$

Mañanas:

- $\Delta_1 = \text{trapezoidal } (-\infty, -\infty, 25027)$
- $\Delta_2 = \text{triangular } (25027, 28802, 31468)$
- $\Delta_3 = \text{trapezoidal } (28802, 31468, \infty, \infty)$

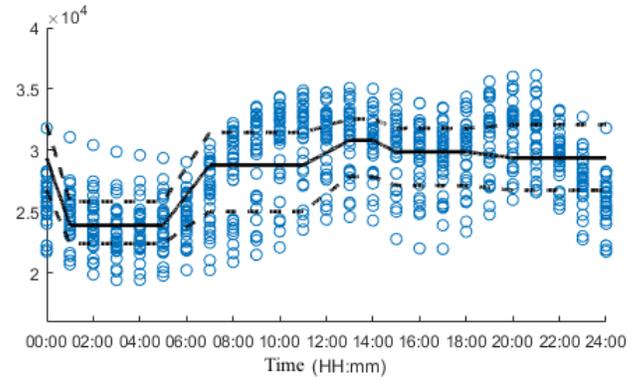


Figure 4. F-transformada inversa de  $T$ ,  $T^\uparrow$  y  $T^\downarrow$ .

Mediodías:

- $\Delta_1 = \text{trapezoidal } (-\infty, -\infty, 27863)$
- $\Delta_2 = \text{triangular } (27863, 30826, 32550)$
- $\Delta_3 = \text{trapezoidal } (30826, 32550, \infty, \infty)$

Tardes:

- $\Delta_1 = \text{trapezoidal } (-\infty, -\infty, 27129)$
- $\Delta_2 = \text{triangular } (27129, 29877, 31804)$
- $\Delta_3 = \text{trapezoidal } (29877, 31804, \infty, \infty)$

Noches:

- $\Delta_1 = \text{trapezoidal } (-\infty, -\infty, 26754)$
- $\Delta_2 = \text{triangular } (26754, 29391, 32105)$
- $\Delta_3 = \text{trapezoidal } (29391, 32105, \infty, \infty)$

Las gráficas de las particiones difusas descritas arriba se exponen en la Figura 5. Obsérvese que lo que se considera “*generación eléctrica media*” es diferente en cada momento del día; de hecho, lo que se considera *generación eléctrica media* durante las mañanas, es una generación *baja* durante el mediodía. Además, en la Figura 4 mostramos las F-transformadas inversas de  $T$ ,  $T^\uparrow$  y  $T^\downarrow$ . De este modo se puede apreciar de una manera más directa la relación entre los conjuntos difusos que definen la partición condicionada y los datos de partida.

## V. CONCLUSIONES

En este trabajo hemos mostrado cómo definir particiones difusas condicionadas a la satisfacción de cierto atributo difuso. Para ello hemos recordado la metodología de las transformadas difusas y hemos mostrado mediante un ejemplo, cómo definir particiones difusas de tres clases en un contexto de la generación de energía.

Como trabajo futuro, sería conveniente estudiar cómo definir particiones difusas siguiendo la idea subyacente de este trabajo para más de tres clases y/o utilizando diferentes metodologías a la transformadas difusas. Con un cariz más aplicado, sería interesante utilizar este tipo de particiones para definir reglas de inferencia.

## REFERENCES

- [1] BACZYASKI, M., BELIAKOV, G., SOLA, H. B., AND PRADERA, A. *Advances in Fuzzy Implication Functions*. Springer-Verlag Berlin Heidelberg, 2013.
- [2] BEZDEK, J. C. *Pattern Recognition with Fuzzy Objective Functions Algorithms*. Plenum Press, New York, 1981.
- [3] BEZDEK, J. C., EHRLICH, R., AND FULL, W. Fcm: The fuzzy c-means clustering algorithm. *Computers & Geosciences* 10, 2, 191 – 203, 1984.
- [4] BOUCHON, B. AND COHEN, C. Partitions and fuzziness, *Journal of Mathematical Analysis and Applications*, 116, 165–183, 1986.
- [5] BUTNARIU, D. Additive fuzzy measures and integrals, *Journal of Mathematical Analysis and Applications*, 93, 436–452, 1983.
- [6] HOPPNER, F., AND KLAWONN, F. Obtaining interpretable fuzzy models from fuzzy clustering and fuzzy regression. in *Fourth International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies*, 162–165, 2000.
- [7] MADRID, N. An extension of f-transforms to more general data: Potential applications. *Soft Comput.* 21, 13, 3551–3565, 2017.
- [8] PERFILIEVA, I. Fuzzy transforms: Theory and applications. *Fuzzy Sets and Systems* 157, 8, 993 – 1023, 2006.
- [9] PERFILIEVA, I., HURTÍK, P. DI MARTINO, F. AND SESSA, S. Image reduction method based on the F-transform *Soft Computing*, 21(7), 1847 – 1861, 2017.
- [10] RUSPINI, E. H. A new approach to clustering, *Information and Control*, 15, 22–32, 1969.

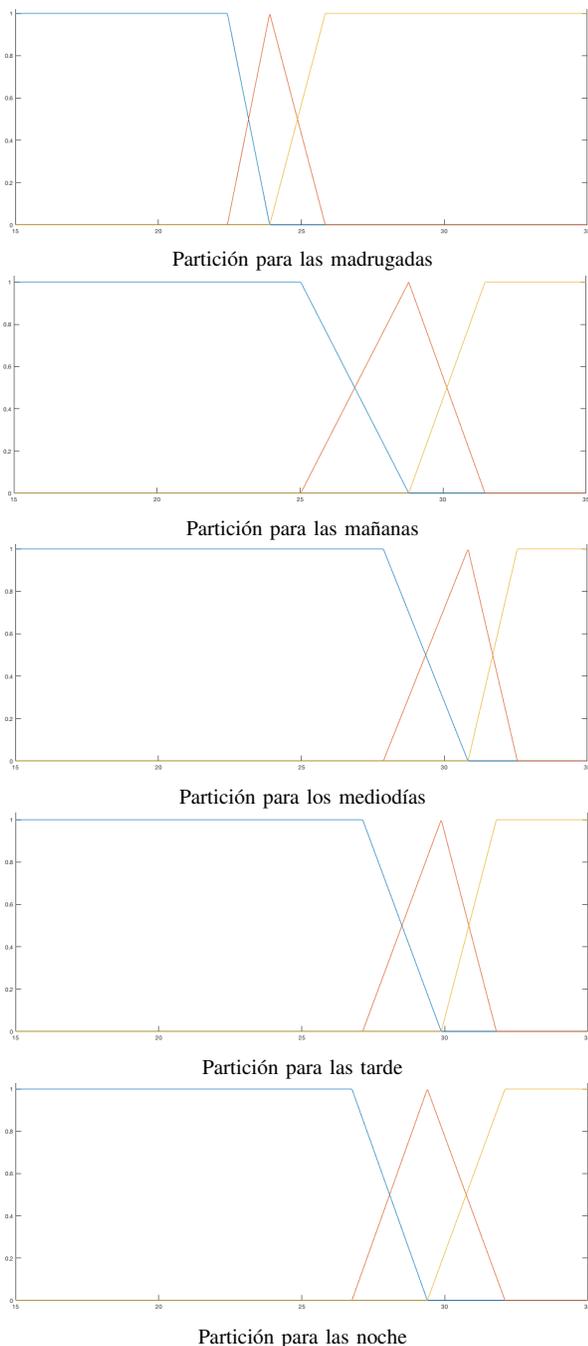


Figure 5. Las gráficas de las cinco particiones difusas de la generación eléctrica condicionadas al momento del día considerado.

**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

**ESTYLF 5: SESIÓN ESPECIAL:  
SOFT COMPUTING  
EN APRENDIZAJE**

**Organizadores:**

MIKEL GALAR, JOSÉ ANTONIO SANZ







# A PageRank-based method to extract fuzzy expressions as features in supervised classification problems\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Pablo Carmona

*Industrial Engineering School*  
*University of Extremadura*  
Badajoz, Spain

Juan Luis Castro

*Department of Computer Science and Artificial Intelligence*  
*University of Granada*  
Granada, Spain

Jesús Lozano

*Industrial Engineering School*  
*University of Extremadura*  
Badajoz, Spain

José Ignacio Suárez

*Industrial Engineering School*  
*University of Extremadura*  
Badajoz, Spain

**Abstract**—This work presents a new ranking method inspired on PageRank to reduce the dimensionality of the feature space in supervised classification problems. More precisely, as it relies on a weighted directed graph, it is ultimately inspired on TextRank, a PageRank based method that adds weights to the edges to express the strength of the connections between nodes. The method is based on dividing each original feature used to describe the training set into a set of fuzzy predicates and then ranking all of them by their ability to differentiate among classes in the light of this training set. The fuzzy predicates with the best scores can be then used as new features, replacing the original ones. The novelty of the proposal relies on being an approach halfway between feature selection and feature extraction approaches, being able to improve the discrimination ability of the original features but preserving the interpretability of the new features in the sense that they are fuzzy expressions. Preliminary results supports the suitability of the proposal.

**Index Terms**—fuzzy logic, supervised classification, ranking methods, feature selection, feature extraction, PageRank, TextRank

# Un estudio sobre el uso de diferentes familias de funciones de fusión para la combinación de clasificadores en la estrategia Uno-contra-Uno

M. Uriz, D. Paternain, H. Bustince, M. Galar

*Departamento de Estadística, Informática y Matemáticas, Universidad Pública de Navarra,*

Campus Arrosadía s/n, 31006 Pamplona, España

{mikelxabier.uriz, daniel.paternain, bustince, mikel.galar}@unavarra.es

**Resumen**—Es este trabajo estudiamos el uso de diferentes familias de funciones fusión para la combinación de clasificadores en un sistema de múltiples clasificadores formado por clasificadores Uno-contra-Uno (del inglés *One-vs-One*, OVO). OVO es una estrategia de descomposición usada para tratar los problemas de clasificación multi-clase, donde el problema original se divide en tantos problemas como pares de clases. En los sistemas de múltiples clasificadores se combinan los clasificadores que provienen de diferentes paradigmas como máquinas de vectores de soporte, algoritmos de inducción de reglas o árboles de decisión. En la literatura, se han desarrollado varios métodos de selección de clasificadores para este tipo de sistemas, donde se busca el clasificador más adecuado para cada par de clases. En este trabajo consideramos el problema desde una perspectiva diferente, con el objetivo de analizar el comportamiento de diferentes familias de funciones fusión para combinar los clasificadores. De hecho, un sistema de múltiples clasificadores OVO puede verse como un problema de toma de decisión multi-experto. En este contexto, para las funciones de fusión que dependen de pesos o medidas difusas, proponemos obtener los parámetros necesarios a partir de los datos. Apoyados en un fuerte análisis experimental, mostramos que la función de fusión utilizada es un factor clave en el sistema final. Además, aquellas funciones basadas en pesos o en medidas difusas pueden permitir modelar mejor el problema de agregación.

**Index Terms**—Agregaciones, Funciones de fusión, clasificación, One-vs-One, Sistema de múltiples clasificadores

## I. INTRODUCCIÓN

En aprendizaje automático, la clasificación consiste en aprender una función (clasificador) utilizando datos etiquetados capaz de asignar la etiqueta correcta a nuevos patrones. Entre los problemas de clasificación se pueden considerar dos escenarios dependiendo del número de clases a distinguir: binario (2 clases) y problemas multi-clase. La clasificación multi-clase generalmente es más difícil ya que la asignación de las fronteras de decisión se vuelve más compleja. Una posible solución para hacer frente a esta dificultad es utilizar estrategias de descomposición [1], donde se divide el problema multi-clase original en problemas binarios más fáciles de resolver. Evidentemente, esta simplificación en la fase de aprendizaje conlleva un coste en la fase de combinación, donde las salidas de todos los clasificadores que se han aprendido en cada nuevo sub-problema deben ser combinados.

Una de las estrategias de descomposición más utilizada es *One-vs-One* (OVO). En OVO, se crean tantos sub-problemas

nuevos como pares de clases diferentes, y cada sub-problema es abordado por un clasificador base independiente. Las nuevas instancias son clasificadas sometiéndolas a todos los clasificadores base, donde se combinan sus salidas. Una ventaja importante de esta técnica es que generalmente funciona mejor incluso cuando el clasificador subyacente es capaz de abordar el problema multi-clase directamente [2].

En este trabajo, nos centramos en la estrategia OVO y más específicamente en la fase de combinación de los Sistemas de Múltiples Clasificadores (SMC) formados por clasificadores OVO. Un SMC es un conjunto formado por clasificadores provenientes de diferentes paradigmas de aprendizaje [3]. En el caso de OVO, la idea es que clasificadores diferentes pueden adaptar mejor la clasificación de cada par de clases. Por esta razón, varios trabajos previos han considerado la selección del mejor clasificador para cada par de clases en los SMC [4], [5]. En este trabajo, nuestro objetivo es abordar este problema como un problema de toma de decisión multi-experto, donde tenemos los diferentes expertos (tipos de clasificadores) y sus matrices de confianza para las alternativas consideradas (clases). En este contexto, queremos estudiar la influencia de las funciones de fusión consideradas para combinar las matrices de los diferentes expertos en una única.

En las últimas décadas, el estudio de las funciones de agregación ha crecido significativamente, ya que la necesidad de fusionar o agregar información cuantitativa surge en casi todas las aplicaciones [6], [7], [8], [9]. Sin embargo, en los últimos años, se han propuesto nuevas extensiones de las funciones de agregación, que son capaces de modelar la interacción entre los datos de una mejor manera a pesar de que las propiedades clásicas exigidas a las agregaciones, como la monotonía, no se satisfagan [10], [11]. Desde un punto de vista amplio, estas extensiones se llaman funciones de fusión [12].

Uno de los ejemplos de funciones de fusión que son capaces de modelar la importancia de las entradas o de las interacciones entre ellas son la integral discreta de Choquet [13] y sus extensiones [10], que están basadas en medidas difusas. En este trabajo, proponemos construir estas medidas directamente del conocimiento que podemos extraer de los expertos (clasificadores) utilizando los datos de entrenamiento.

Para realizar este estudio, utilizamos veintiocho conjuntos de datos de KEEL [14] y consideramos el uso de test es-



estadísticos no paramétricos para analizar los resultados obtenidos [15]. Dado que estamos tratando con conjuntos de datos de múltiples clases, no consideraremos solo la precisión para evaluar los resultados, sino que también utilizaremos otras métricas que se centran en la correcta clasificación de todas las clases, como el promedio de precisiones o la media geométrica. Desarrollaremos un estudio jerárquico, donde consideraremos comparaciones intra e inter-familiares para analizar el uso de las diferentes funciones de fusión.

La estructura del artículo es la siguiente. En la sección 2, se recuerdan las diferentes funciones de fusión consideradas en este trabajo. La sección 3 contiene una introducción a la descomposición de los problemas multi-clase, la estrategia OVO y el SMC formado por clasificadores OVO. En la sección 4, describimos con detalle el marco experimental considerado en este estudio, incluyendo como establecer los parámetros de las funciones de fusión parametrizables. La sección 5 contiene el análisis de los resultados obtenidos. Finalmente, en la Sección 6 mostramos las conclusiones obtenidas del estudio.

## II. FUNCIONES DE FUSIÓN

En la literatura reciente, la agregación de información cuantitativa se ha abordado mediante el uso de las funciones de agregación. Una función de agregación se define como una función  $f: [0, 1]^n \rightarrow [0, 1]$  (el intervalo  $[0, 1]$  puede ser extendido a cualquier otro intervalo) tal que  $f(0, \dots, 0) = 0$ ,  $f(1, \dots, 1) = 1$ , satisfaciendo la propiedad de monotonía, es decir, si  $x_i \leq y_i$  para todo  $i \in \{1, \dots, n\}$ , entonces  $f(x_1, \dots, x_n) \leq f(y_1, \dots, y_n)$  [6], [7], [8], [9]. De acuerdo a [6], [7], las principales clases de funciones de agregación son las siguientes: promedios (o medias), conjuntivas, disyuntivas y mixtas. En este trabajo nos hemos centrado principalmente (pero no exclusivamente) en las funciones de agregación promedio, aquellas que están acotadas por el mínimo y el máximo de las entradas.

Sin embargo, en los últimos dos años la propiedad de monotonía de las funciones de agregación se ha visto innecesaria en algunas aplicaciones e incluso se ha generalizado a nuevos tipos de monotonía (ver por ejemplo [12]). A partir de estos estudios, se han definido nuevos conceptos como el de función de pre-agregación [10] o función de fusión interna [11]. Dado que en este artículo modelamos la agregación de datos desde un amplio punto de vista y utilizamos varias funciones no monótonas, hemos utilizado la definición más general de funciones de fusión (ver [12]).

Para clasificar el gran número de funciones de fusión consideradas en este trabajo, hemos establecido una clasificación basada en la necesidad de definir pesos o medidas asociadas a ellas. Básicamente hemos considerado: funciones de fusión no ponderadas, funciones de fusión ponderadas y funciones de fusión basadas en medidas.

**Funciones de fusión no ponderadas** En esta sub-sección consideramos varias funciones de agregación clásicas:

- La media aritmética  $AM(x_1, \dots, x_n) = \frac{1}{n}(x_1, \dots, x_n)$ ;

- La mediana

$$MED(x_1, \dots, x_n) = \begin{cases} \frac{1}{2}(x_{(k)} + x_{(k+1)}) & \text{si } n = 2k \text{ es par,} \\ x_{(k)} & \text{si } n = 2k - 1 \text{ es impar,} \end{cases}$$

donde  $x_{(k)}$  es el  $k$  elemento más largo (más pequeño) de  $x_1, \dots, x_n$ ;

- La media geométrica  $GM(x_1, \dots, x_n) = (\prod_{i=1}^n x_i)^{\frac{1}{n}}$ ;
- La media armónica  $HM(x_1, \dots, x_n) = n \left( \sum_{i=1}^n \frac{1}{x_i} \right)^{-1}$ .

**Funciones de fusión ponderadas** En esta sub-sección consideramos funciones de agregación cuyo comportamiento es modelado por un vector de pesos. Esto quiere decir que no todas las entradas son igualmente importantes para calcular el valor agregado, un hecho que claramente nos permite incorporar cierta información externa para el proceso de fusión. Consideramos los vectores de pesos  $w = (w_1, \dots, w_n)$  que satisfagan  $w_i \in [0, 1]$  y  $\sum_{i=1}^n w_i = 1$  [6], [7].

Las funciones de agregación ponderadas son:

- Media aritmética ponderada  $WAM(x_1, \dots, x_n) = \sum_{i=1}^n w_i x_i$ ;
- Operador OWA  $OWA(x_1, \dots, x_n) = \sum_{i=1}^n w_i x_{(i)}$ , donde  $(\cdot)$  es una permutación tal que  $x_{(1)} \geq \dots \geq x_{(n)}$ .

**Funciones de fusión basadas en medidas** En esta sub-sección consideramos el conjunto de funciones de fusión basadas en medidas difusas. A diferencia de las funciones de fusión ponderadas, las cuales te permiten modelar la importancia de cada entrada individual, el uso de las medidas difusas nos permiten modelar de manera más general la interacción entre las entradas. En este sentido, la importancia no solo se da a cada entrada individual sino que se asigna también a colecciones (grupos o coaliciones) de entradas. Obviamente, la construcción de la medida difusa es el punto clave para esta familia de funciones de fusión.

*Definition 1:* Sea  $\mathcal{N} = \{1, \dots, n\}$ . Una medida difusa discreta es una función  $m: 2^{\mathcal{N}} \rightarrow [0, 1]$  monótona, es decir,  $m(S) \leq m(T)$  siempre que  $S \subseteq T$  y satisfaga  $m(\emptyset) = 0$  y  $m(\mathcal{N}) = 1$ .

Una vez visto el concepto de medida difusa podemos definir la integral de Choquet, que es un ejemplo destacado de operador promedio basado en medidas. Empezamos considerando una permutación  $\sigma$  tal que  $x_{\sigma(1)} \leq \dots \leq x_{\sigma(n)}$  con la convención  $x_{\sigma(0)} = 0$ :

- La integral discreta de Choquet

$$Ch(x_1, \dots, x_n) = \sum_{i=1}^n (x_{\sigma(i)} - x_{\sigma(i-1)}) * m(\{\sigma(i), \dots, \sigma(n)\})$$

Como hemos mencionado antes, en [10] se proponen extensiones de las agregaciones, llamados funciones de pre-agregación. Uno de los métodos más sencillos para construir las pre-agregaciones es cambiando ciertas operaciones en la integral de Choquet. Hemos considerado las siguientes funciones de pre-agregación:

- Integral de Choquet basada en la t-norma mínimo

$$Ch_M(x_1, \dots, x_n) = \sum_{i=1}^n \min\{x_{\sigma(i)} - x_{\sigma(i-1)}, m(\{\sigma(i), \dots, \sigma(n)\})\};$$

- Integral de Choquet basada en la t-norma de Lukasiewicz

$$Ch_L(x_1, \dots, x_n) = \sum_{i=1}^n \max\{0, x_{\sigma(i)} - x_{\sigma(i-1)} + m(\{\sigma(i), \dots, \sigma(n)\})\}$$

### III. ONE-VS-ONE PARA PROBLEMAS MULTI-CLASE Y SISTEMAS DE MÚLTIPLES CLASIFICADORES

En esta sección introducimos los problemas de clasificación y, más específicamente, la estrategia One-vs-One (OVO) para tratar los problemas de clasificación multi-clase y los sistemas de múltiples clasificadores con el objetivo de mejorar el rendimiento de la clasificación mediante la combinación de varios clasificadores.

En aprendizaje automático, un problema de clasificación consiste en aprender un sistema (clasificador) capaz de predecir la salida deseada (etiqueta) para cada patrón de entrada. Formalmente, el objetivo es buscar un función  $\mathbb{A}^i \rightarrow \mathbb{C}$  donde  $a_1, \dots, a_i \in \mathbb{A}$  son los atributos que caracterizan cada ejemplo de entrada  $x_1, \dots, x_n$  y cada entrada tiene asociada la salida deseada  $y_j \in \mathbb{C} = \{c_1, \dots, c_m\}$ . Se espera que el clasificador generalice bien a nuevos ejemplos del problema que no se han considerado en el entrenamiento, esto es, debería tener una buena habilidad de generalización.

Un problema de clasificación multi-clase se da cuando el número de clases es mayor que dos ( $|\mathbb{C}| > 2$ ). Estos problemas se consideran más difíciles que los problemas de clasificación binarios dado que las fronteras de decisión son generalmente más complejas y existe un mayor solapamiento entre clases. Es por esto que se crearon las estrategias de descomposición [1], para tratar con los problemas de clasificación multi-clase dividiendo el problema original en problemas de clasificación binarios más fáciles de resolver. Por lo tanto, se aprende un clasificador binario por cada nuevo problema, conocidos como clasificadores base, y se combinan las salidas de estos clasificadores cuando se quiere clasificar un nuevo ejemplo no etiquetado. Se ha probado que estas estrategias no son solo útiles cuando se trabaja con clasificadores que solo soportan problemas binarios (como las máquinas de vectores de soporte, SVM [16]), sino que también con clasificadores que soportan la clasificación multi-clase. En estos casos, el rendimiento final se puede mejorar descomponiendo el problema [2].

#### III-A. La estrategia One-Vs-One

La estrategia OVO es la estrategia de descomposición más utilizadas. En OVO, se divide un problema con  $m$  clases en tantos problemas como posibles pares de clases haya, generando  $m(m-1)/2$  sub-problemas que son abordados mediante clasificadores base independientes. En cada sub-problema, solo se consideran los ejemplos que pertenezcan al par de clases considerado, descartando el resto. A la hora de clasificar un nuevo ejemplo, se somete éste a todos los clasificadores cuyas salidas tienen que ser combinadas para decidir la clase final. Para realizar la combinación, generalmente se almacenan todas las salidas en una matriz de confianza (Eq. 1) donde cada posición  $r_{ij}, r_{ji} \in [0, 1]$  corresponde al grado de confianza del clasificador distinguiendo las clases  $\{C_i, C_j\}$ . Dado que la mayoría de clasificadores devuelven la confianza basada

en estimaciones de probabilidad, generalmente  $r_{ji}$  se calcula como  $r_{ji} = 1 - r_{ij}$ . Sin embargo, si este no es el caso, como ocurre con los clasificadores basados en reglas difusas [17], la matriz de confianza se normaliza para que  $r_{ij} + r_{ji} = 1$  [17].

$$R = \begin{pmatrix} - & r_{12} & \dots & r_{1m} \\ r_{21} & - & \dots & r_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \dots & - \end{pmatrix} \quad (1)$$

Finalmente, se combinan las salidas de los clasificadores base por cada fila (clase) y se asigna la clase que consiga la mayor confianza total. En la literatura, se han desarrollado varias estrategias de combinación para este propósito. Se realizó una completa revisión en [2] y se han desarrollado varias extensiones de combinación considerando la selección de clasificadores y el mecanismo de ponderación [18], [19]. En este trabajo, consideramos la estrategia del voto ponderado (WV) [20] ya que se ha demostrado que es un método simple y robusto. En este método, cada clasificador base vota por ambas clases basándose en la confianza dada por el par de clases. Finalmente, se devuelve la clase con mayor valor

$$Class = \arg \max_{i=1, \dots, m} \sum_{1 \leq j \neq i \leq m} r_{ij}. \quad (2)$$

#### III-B. Sistema de Múltiples clasificadores y OVO

La estrategia OVO se puede ver como un modelo ensemble [2], donde se utiliza una combinación de clasificadores con el objetivo de mejorar los resultados de un único clasificador. Este término se considera generalmente para describir la combinación de variantes menores del mismo clasificador. De otra manera, un sistema de múltiples clasificadores (SMC) es una categoría más amplia incluyendo esas combinaciones considerando el uso de diferentes modelos de clasificación [3].

Recientemente, se han considerado varios trabajos centrados en la hibridación de ensembles OVO (donde se utiliza el mismo clasificador base para cada sub-problema, p. ej. SVM) con SMC. Esto es, para construir varios ensembles OVO con diferentes clasificadores (por ejemplo, uno utilizado SVM, otro utilizando métodos de inducción de reglas y otro utilizando árboles de decisión) y para combinar las salidas de todos los ensembles OVO para tomar la decisión final.

Otros trabajos se han centrado en seleccionar estática o dinámicamente el mejor clasificador para distinguir cada par de clases [4], [5]. Sin embargo, nuestro objetivo en este trabajo es ver el problema desde un perspectiva diferente para probar el uso de diferentes funciones de fusión en la combinación de los diferentes clasificadores.

Una vez que se han entrenado todos los clasificadores OVO del SMC (asumiendo que teniendo tres clasificadores diferentes y un problema de cuatro clases, tendríamos  $3 \cdot 4 \cdot (4-1)/2$  clasificadores), se clasifica un nuevo ejemplos sometiéndolo a todos los clasificadores. Como resultado, en vez de obtener una única matriz de confianza, tendríamos tantas matrices como clasificadores considerados (tres en nuestro ejemplo). El problema es cómo combinar estas matrices en una única donde podamos aplicar la estrategia WV para clasificar el ejemplo. Es por esto que podemos entender el problema como un problema



de toma de decisión multi-experto. Nuestra propuesta en este trabajo es combinar las diferentes matrices de confianza utilizando las funciones de fusión. Nuestro objetivo es estudiar cómo el uso de diferentes funciones de fusión afecta al rendimiento del SMC. Para ello, consideraremos las diferentes funciones de fusión mencionadas en la sección anterior y propondremos diferentes mecanismos para asignar los pesos o crear las medidas difusas en las funciones que requieran estos parámetros. Más detalles acerca de la obtención de dichos parámetros se dan en la Sección IV-B.

#### IV. MARCO EXPERIMENTAL

##### IV-A. Datasets, evaluación, test estadísticos y algoritmos

Para llevar a cabo el estudio experimental, hemos utilizado veintiocho conjuntos de datos numéricos del repositorio de datos de KEEL [14], cuyas características principales se muestran en la Tabla I.

Tabla I  
RESUMEN DE LAS CARACTERÍSTICAS DE LOS CONJUNTOS DE DATOS UTILIZADOS EN EL ESTUDIO EXPERIMENTAL.

Dataset	#Ej.	#Atr.	#Clas.	Dataset	#Ej.	#Atr.	#Clas.
autos	159	25	6	nursery	1296	8	5
balance	625	4	3	pageblocks	548	10	5
car	1728	6	4	penbased	1100	16	10
cleveland	297	13	5	satimage	643	36	7
contraceptive	1473	9	3	segment	2310	19	7
dermatology	358	34	6	shuttle	2175	9	7
ecoli	336	7	8	splice	319	60	3
flare	1066	11	6	tae	151	5	3
glass	214	9	7	thyroid	720	21	3
hayes-roth	132	4	3	vehicle	846	18	4
iris	150	4	3	vowel	990	13	11
led7digit	500	7	10	wine	178	13	3
lymphography	148	18	4	yeast	1484	8	10
newthyroid	215	5	3	zoo	101	16	7

El resultado de cada método y conjunto de datos se ha obtenido utilizando validación cruzada con 5 particiones. Además, para analizar apropiadamente los resultados obtenidos, hemos aplicado test estadísticos no paramétricos[15]. Más específicamente, hemos utilizado el test de Wilcoxon para comparar un par de métodos, mientras que se considera el test de rangos alineados de Friedman para comparar un grupo de métodos con el objetivo de detectar si existen diferencias estadísticas. En tal caso, se utiliza el test *post-hoc* de Holm para buscar los algoritmos que rechazan la hipótesis nula de equivalencia frente al método de control seleccionado.

Dado que estamos tratando con problemas multi-clase, hemos considerado tres medidas de rendimiento para analizar los resultados obtenidos: el ratio de precisión (Acc), esto es, el ratio de los ejemplos clasificados correctamente; media aritmética (AvgAcc) y media geométrica (GM) de los ratios de los ejemplos correctamente clasificados por cada clase. Por lo tanto, Acc nos da un medida global de la calidad del algoritmo, mientras que AvgAcc y GM se centran más en medir apropiadamente si todas las clases del problema se están clasificando apropiadamente.

Respecto a los algoritmos de clasificación considerados para formar nuestro SMC, hemos considerado los siguientes (los cuales también fueron considerados en nuestros trabajos previos [2], [18], [19]): *Support Vector Machine* (SVM) [16], *C4.5 decision tree* [21], *k-Nearest Neighbors* (kNN) [22],

*Repeated Incremental Pruning to Produce Error Reduction* (Ripper) [23], *Positive Definite Fuzzy Classifier* (PDFC)[24].

Estos clasificadores se han entrenado utilizando los parámetros mostrados en la Tabla II. Estos valores son comunes para todos los problemas, y se han seleccionado de acuerdo a las recomendaciones de los autores correspondientes, que son sus valores por defecto incluidos en KEEL, software [14] utilizado para realizar nuestros experimentos.

Tabla II  
ESPECIFICACIÓN DE LOS PARÁMETROS PARA LOS CLASIFICADORES BASE UTILIZADOS EN LA EXPERIMENTACIÓN.

Algoritmo	Parámetros
SVM <sub>Poly</sub>	C = 1.0, Tolerance Parameter = 0.001, Epsilon = 1.0E-12, Kernel Type = Polynomial Polynomial Degree = 1, Fit Logistic Models = True
SVM <sub>Puk</sub>	C = 100.0, Tolerance Parameter = 0.001, Epsilon = 1.0E-12, Kernel Type = Puk PukKernel $\omega = 1.0$ , PukKernel $\sigma = 1.0$ , Fit Logistic Models = True
C4.5	Prune = True, Confidence level = 0.2, Minimum number of item-sets per leaf = 2
3NN	k = 3, Distance metric = HVDM
Ripper	Size of growing subset = 66%, Repetitions of the optimization stage = 2
PDFC	C = 100.0, Tolerance Parameter = 0.001, Epsilon = 1.0E-12, Kernel Type = Polynomial Polynomial Degree = 1, PDRF Type = Gaussian

Debemos recordar que las matrices de confianza representan las confianzas obtenida de los clasificadores. Dado que no todos los clasificadores devuelven la confianza directamente, detallamos cómo se han obtenido.

- **SVM** – Estimación de la probabilidad de la SVM
- **C4.5** – Precisión de la hoja realizando la predicción (ejemplos de entrenamiento bien clasificados dividido por el número total de ejemplos de entrenamiento cubiertos).
- **kNN** – Confianza basada en distancia.  $Confianza = \frac{\sum_{l=1}^k \frac{e_l}{d_l}}{\sum_{l=1}^k \frac{1}{d_l}}$  Donde  $d_l$  es la distancia entre el patrón de entrada y el vecino  $l$  y  $e_l = 1$  si el vecino  $l$  es de la clase y 0 en otro caso.
- **Ripper** – Precisión de la regla utilizada en la predicción (como en C4.5 considerando reglas en vez de hojas).
- **PDFC** – La predicción del clasificador, esto es, la confianza es 1 para la clase predicha.

##### IV-B. Parámetros para las funciones de fusión

En lo sucesivo presentamos el método para estimar los parámetros requeridos por algunas funciones de fusión.

**Cálculo de pesos** Para la media aritmética ponderada necesitamos establecer los pesos para cada entrada (clasificador, p. ej., SVM, 3NN, ...). Establecemos cada peso como la precisión normalizada de cada método en el conjunto de entrenamiento, esto es,  $w_i = \frac{Acc_i}{\sum_{j=1}^n Acc_j}$  para todo  $i \in \{1, \dots, n\}$ .

Además, hemos utilizado dos versiones diferentes para las funciones de fusión ponderadas: un enfoque global y otro local. En el enfoque global, asignamos un peso a cada clasificador. Sin embargo, en el enfoque local, cada clasificador obtiene un peso por cada problema individual (precisión sobre cada par de clases).

El cálculo de los pesos para los operadores OWA se realiza mediante el uso de cuantificadores difusos crecientes (ver [25]), y son dados por  $w_i = Q\left(\frac{i}{n}\right) - Q\left(\frac{i-1}{n}\right)$  para

todo  $i \in \{1, \dots, n\}$ . En este trabajo hemos considerado 3 cuantificadores difusos diferentes obteniendo tres operadores OWA: 'al menos la mitad' (OWA\_alh) con  $a = 0, b = 0,5$ ; 'la mayor cantidad posible' (OWA\_amap) con  $a = 0,5, b = 1$ ; y 'la mayoría de' (OWA\_mot) con  $a = 0,3, b = 0,8$ .

**Valores de la medida difusa** Para las funciones de fusión basadas en medidas, necesitamos construir una medida difusa  $m: 2^{\mathcal{N}} \rightarrow [0, 1]$  con  $\mathcal{N} = \{1, \dots, n\}$ , siendo  $n$  el número de clasificadores considerados. Empezamos considerando la medida difusa uniforme  $m_U$  la cual se construye con  $m_U(A) = \frac{|A|}{n}$  para todo  $A \subseteq \mathcal{N}$  (la integral de Choquet con esta medida equivale a la media aritmética).

Sin embargo, para capturar las interacciones entre clasificadores, utilizaremos no solo la precisión de los clasificadores individuales sino también la precisión de cada posible combinación de clasificadores. Denotaremos estas precisiones como  $Acc_A$ , para todo  $A \subseteq \mathcal{N}$ . Ahora, por cada nivel de la medida difusa (todos los elementos de la medida difusa con la misma cardinalidad), calculamos la media aritmética de las precisiones en cada nivel correspondiente, llamándola  $MeanAcc_i$  para todo  $i \in \{1, \dots, n\}$ . Finalmente, el valor de la medida difusa para cada  $A \subseteq \mathcal{N}$  vendrá dado por

$$m(A) = m_U(A)(1 + Acc_A - MeanAcc_{|A|}). \quad (3)$$

Analizando esta expresión, el valor de la medida difusa asociado a los clasificadores que son mejores que la precisión media en el mismo nivel aumentarán (respecto a la medida uniforme) y el valor de aquellos que son peores decrementarán. De manera similar al cálculo anterior de pesos, consideraremos un enfoque global y otro local.

Es importante hacer notar que no podemos garantizar la monotonía de  $m$  para todo posible valor de  $Acc$  y  $MeanAcc$ . Para corregir esto, y basándonos en la verificación de monotonía dada en [26], hemos utilizado una corrección top-down: empezamos en el nivel superior de la medida  $m(\mathcal{N})$  y vamos evaluando los valores de la medida en los niveles inferiores  $m(A)$  donde  $|A| = n - 1$ . Si encontramos algún  $A$  tal que  $m(A) > m(\mathcal{N})$ , entonces establecemos  $m(A) = m(\mathcal{N})$ . Una vez que el nivel  $n - 1$  es verificado (con respecto al nivel  $n$ ), verificamos el nivel  $n - 2$  con respecto al nivel  $n - 1$ . Repetimos este proceso hasta que la medida satisfaga el criterio de monotonía.

## V. ESTUDIO EXPERIMENTAL

Por un lado, la Tabla III muestra las precisiones (Acc), la media aritmética (AvgAcc) y la media geométrica (GM) de las precisiones de cada clase obtenidas sobre el conjunto de test utilizando diferentes funciones de fusión para combinar las matrices OVO en el SMC. El mejor resultado de cada métrica esta subrayado.

Por otro lado, la Figura 1 resume el estudio estadístico llevado a cabo para cada métrica de rendimiento para analizar cuál es la función de fusión que mejor funciona en cada caso. Para crear esta figura, hemos enfrentada las funciones dentro de cada familia utilizando el test de rangos alineados de Friedman. Luego, se comparan los mejores de cada familia

Tabla III  
RESULTADOS MEDIOS OBTENIDOS EN TODOS LOS CONJUNTOS DE TEST CON DIFERENTES FUNCIONES DE FUSIÓN PARA CADA MÉTRICA DE RENDIMIENTO

Family	Fusion	Acc	AvgAcc	GM
Unweighted	AM	0.8544	0.7911	0.6240
	MED	0.8580	0.7951	0.6332
	GM	0.8285	0.7535	0.5588
	HM	0.8252	0.7515	0.5610
Weighted	WAM	0.8544	0.7916	0.6308
	WAM_local	0.8481	0.7893	0.6344
	OWA_alh	0.8573	0.7996	0.6448
	OWA_amap	0.8496	0.7815	0.6073
	OWA_mot	0.8554	0.7921	0.6254
Choquet	Ch	0.8552	0.7940	0.6305
	Ch_local	0.8541	0.7924	0.6334
	Ch <sub>L</sub>	0.8487	0.7789	0.6087
	Ch <sub>L</sub> _local	0.8502	0.7803	0.6088
	Ch <sub>M</sub>	0.8548	0.7939	0.6395
	Ch <sub>M</sub> _local	0.8556	0.7964	0.6397

en una etapa final que nos da la mejor función de fusión. En cada comparación, mostramos los rangos obtenidos por cada método (cuanto menor, mejor) y marcamos con **negrita** los rangos en los que el test post-hoc detecta diferencias significativas (con  $\alpha = 0,1$ ) en favor del método ganador.

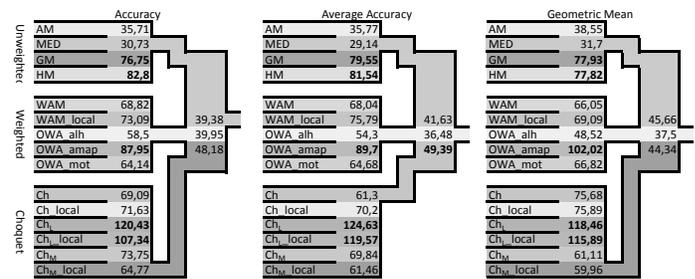


Figura 1. Estudio estadístico jerárquico comparando las funciones de fusión en cada familia y la mejor de cada familia para cada medida de rendimiento utilizando el test de rangos alineados de Friedman.

Finalmente, completamos el análisis estadístico comparando la media aritmética (AM, función comúnmente utilizada) con el ganador de cada familia. Estas comparaciones se muestran en la Tabla IV, donde se muestra el p-valor de la comparación y si existen o no diferencias estadísticas en **negrita**.

Tabla IV  
COMPARACIÓN DE LA AM CONTRA LAS MEJORES FUNCIONES DE CADA FAMILIA UTILIZANDO EL TEST DE WILCOXON.

Perf. Measure	Unweighted	Weighted	Choquet
Acc	MED	OWA_alh	Ch <sub>M</sub> _local
	<b>0.0152</b>	<b>0.0298</b>	0.7610
AvgAcc	MED	OWA_alh	Ch
	<b>0.0194</b>	<b>0.0126</b>	<b>0.0994</b>
GM	MED	OWA_alh	Ch <sub>M</sub> _local
	<b>0.0169</b>	<b>0.0036</b>	<b>0.0400</b>

Viendo estos resultados, podemos observar los siguientes hechos:

- Analizando los resultados por cada familia, vemos que dentro de las funciones no ponderadas, AM y MED son



las que mejores resultados obtienen. Viendo los test de Wilcoxon vemos que MED supera estadísticamente a AM en las tres las medidas de rendimiento.

Analizando las funciones ponderadas, OWA\_alh es la que mejor funciona, aunque solo existen diferencias estadísticas con respecto a OWA\_amap. Esto es posible debido a que dicho OWA actúa como el promedio de los tres clasificadores más competitivos. En este caso, obtener los pesos de los datos (WAM y su versión local) obtiene peores resultados que estableciendo los pesos de manera predefinida. Finalmente, en cuanto a las funciones basadas en medidas difusas, las pre-agregaciones que utilizan el mínimo son mejores en casi todos los casos, mostrando robustez frente a la medida de rendimiento considerada (aunque no se encuentran diferencias estadísticas)

Se podrían esperar mejores resultados en los casos donde los parámetros se obtienen de los datos. Aunque no se han encontrado diferencias estadísticas con respecto a la WAM y a la Choquet, en el futuro nuestro objetivo es centrarnos en estas funciones e intentar mejorar el modelado de los parámetros para ser más competitivos. De hecho, los operadores OWA son un caso particular de la integral de Choquet y, por lo tanto, parece razonable poder obtener una medida difusa que por lo menos llegue al comportamiento de cualquier OWA.

- Finalmente, analizando la Tabla IV se puede ver que la función comúnmente utilizada (AM) es superada estadísticamente por la MED y la OWA\_alh en todos los casos y por la Choquet en los casos de AvgAcc y GM. Por lo tanto, existe un margen de mejora considerando diferentes funciones de fusión.

## VI. CONCLUSIONES

En este trabajo, hemos considerado un SMC formado por clasificadores OVO y hemos enfocado la fase de combinación como un problema de toma de decisión multi-experto. En consecuencia, hemos desarrollado un estudio empírico completo para analizar el comportamiento de las diferentes funciones de fusión. También hemos propuesto diferentes formas de obtener los parámetros para las funciones ponderadas y basadas en medias difusas utilizando los datos. Aunque se esperarían mejores resultados para ese tipo de funciones, los operadores OWA son los que mejores resultados obtienen. Dado que los OWA son un caso particular de medida difusa, se motiva un estudio para construir las medidas difusas de diferentes maneras para mejorar la calidad de sus resultados.

*Agradecimientos.*: Este trabajo ha sido apoyado en parte por el Ministerio Español de Ciencia y Tecnología bajo el Proyecto TIN2016-77356-P (AEI/FEDER, UE).

## REFERENCIAS

- [1] A. C. Lorena, A. C. Carvalho, and J. M. Gama, "A review on the combination of binary classifiers in multiclass problems," *Artificial Intelligence Review*, vol. 30, no. 1-4, pp. 19–37, 2008.
- [2] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, and F. Herrera, "An overview of ensemble methods for binary classifiers in multi-class problems: Experimental study on one-vs-one and one-vs-all schemes," *Pattern Recognition*, vol. 44, no. 8, pp. 1761 – 1776, 2011.
- [3] T. K. Ho, J. J. Hull, and S. N. Srihari, "Decision combination in multiple classifier systems," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 16, no. 1, pp. 66–75, 1994.
- [4] S. Kang, S. Cho, and P. Kang, "Multi-class classification via heterogeneous ensemble of one-class classifiers," *Engineering Applications of Artificial Intelligence*, vol. 43, pp. 35–43, 2015.
- [5] I. Mendialdua, J. M. Martínez-Otzeta, I. Rodríguez-Rodríguez, T. Ruiz-Vázquez, and B. Sierra, "Dynamic selection of the best base classifier in One versus One," *Knowledge-Based Systems*, vol. 85, pp. 298–306, 2015.
- [6] G. Beliakov, A. Pradera, and T. Calvo, *Aggregation Functions: A Guide for Practitioners*. Springer, 2007.
- [7] G. Beliakov, H. Bustince, and A. Pradera, *A Practical Guide to Averaging Functions*, 2nd ed. Springer, 2015.
- [8] T. Calvo, G. Mayor, and R. Mesiar, *Aggregation Operators. New Trends and Applications*. Physica-Verlag, 2002.
- [9] M. Grabisch, J. L. Marichal, R. Mesiar, and E. Pap, *Aggregation Functions*. Cambridge University Press, 2009.
- [10] G. Lucca, J. Sanz, G. Dimuro, B. Bedregal, R. Mesiar, A. Kolesárová, and H. Bustince, "Preaggregation functions: Construction and an application," *IEEE Transactions on Fuzzy Systems*, vol. 24, pp. 260–272, 2016.
- [11] D. Paternain, M. J. Campión, H. Bustince, I. Perfilieva, and R. Mesiar, "Internal fusion functions," *IEEE Transactions on Fuzzy Systems*, InPress.
- [12] H. Bustince, J. Fernandez, A. Kolesárová, and R. Mesiar, "Directional monotonicity of fusion functions," *European Journal of Operational Research*, vol. 244, pp. 300–308, 2015.
- [13] G. Choquet, "Theory of capacities," *Ann. Inst. Fourier*, vol. 5, pp. 1953–1954, 1953.
- [14] J. Alcalá-Fdez, A. Fernández, J. Luengo, J. Derrac, S. García, L. Sánchez, and F. Herrera, "KEEL data-mining software tool: Data set repository, integration of algorithms and experimental analysis framework," *Journal of Multiple-Valued Logic and Soft Computing*, vol. 17:2-3, pp. 255–287, 2011.
- [15] S. García, A. Fernández, J. Luengo, and F. Herrera, "Advanced non-parametric tests for multiple comparisons in the design of experiments in computational intelligence and data mining: Experimental analysis of power," *Information Sciences*, vol. 180, pp. 2044–2064, 2010.
- [16] V. Vapnik, *Statistical Learning Theory*. New York: Wiley, 1998.
- [17] M. Elkano, M. Galar, J. Sanz, A. Fernández, E. Barrenechea, F. Herrera, and H. Bustince, "Enhancing multi-class classification in farc-hd fuzzy classifier: On the synergy between n-dimensional overlap functions and decomposition strategies," *IEEE Transactions on Fuzzy Systems*, vol. 23, no. 5, pp. 1562 – 1580, 2015.
- [18] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, and F. Herrera, "Dynamic classifier selection for one-vs-one strategy: Avoiding non-competent classifiers," *Pattern Recognition*, vol. 46, no. 12, pp. 3412–3424, 2013.
- [19] M. Galar, A. Fernández, E. Barrenechea, and F. Herrera, "DRCW-OVO: Distance-based relative competence weighting combination for one-vs-one strategy in multi-class problems," *Pattern Recognition*, vol. 48, no. 1, pp. 28–42, 2015.
- [20] E. Hüllermeier and S. Vanderlooy, "Combining predictions in pairwise classification: An optimal adaptive voting strategy and its relation to weighted voting," *Pattern Recognition*, vol. 43, no. 1, pp. 128–142, 2010.
- [21] J. R. Quinlan, *C4.5: Programs for Machine Learning*, 1st ed. San Mateo-California: Morgan Kaufmann Publishers, 1993.
- [22] D. W. Aha, D. Kibler, and M. K. Albert, "Instance-based learning algorithms," *Machine Learning*, vol. 6, pp. 37–66, 1991.
- [23] W. W. Cohen, "Fast effective rule induction," in *ICML'95: Proc. of the Twelfth Int. Conf. on Machine Learning*, 1995, pp. 1–10.
- [24] Y. Chen and J. Z. Wang, "Support vector learning for fuzzy rule-based classification systems," *IEEE Transactions on Fuzzy Systems*, vol. 11, no. 6, pp. 716–728, 2003.
- [25] R. Yager, "Quantifier guided aggregation using owa operators," *International Journal of Intelligent Systems*, vol. 11, pp. 49–73, 1998.
- [26] M. Grabisch, "A new algorithm for identifying fuzzy measures and its application to pattern recognition," in *Int. Joint Conf. of the 4th IEEE Int. Conf. on Fuzzy Systems and the 2nd Int. Fuzzy Engineering Symposium*, 1995, pp. 145–150.

# Clustering difuso con pertenencias intervalares

Aranzazu Jurio  
Departamento de Estadística,  
Informática y Matemáticas  
Instituto de Smart Cities  
Universidad Pública de Navarra  
Pamplona, España  
aranzazu.jurio@unavarra.es

Humberto Bustince  
Departamento de Estadística,  
Informática y Matemáticas  
Instituto de Smart Cities  
Universidad Pública de Navarra  
Pamplona, España  
bustince@unavarra.es

Vicenç Torra  
School of Informatics  
University of Skövde  
Skövde, Sweden  
vtorra@ieee.org

**Resumen**—En este trabajo estudiamos cómo solucionar el problema que presentan los outliers a la hora de realizar un proceso de agrupamiento. Para ello, presentamos una función objetivo que extiende a la del algoritmo Fuzzy Cluster Means, mediante el uso de conjuntos intervalo-valorados difusos. En este caso, las pertenencias de cada dato a cada grupo se representan mediante intervalos. Posteriormente, presentamos un algoritmo que minimiza la función objetivo propuesta y mostramos cómo se comporta ante diferentes conjuntos de datos.

**Index Terms**—clustering, intervalo, pertenencia

## I. INTRODUCCIÓN

El problema de clustering o agrupamiento es un problema de clasificación no supervisada cuyo objetivo es encontrar los grupos naturales existentes en un conjunto de datos. Para ello, se basa en la idea de que los datos que pertenecen a un mismo grupo deben compartir características similares, mientras que los datos que pertenecen a diferentes grupos deben diferenciarse en dichas características [4].

Los algoritmos de agrupamiento se pueden dividir de manera general en dos tipos: algoritmos jerárquicos y algoritmos de particiones. Los algoritmos jerárquicos crean un árbol (dendograma) que mide las similitudes entre los datos [5] [9]. Por su parte, los algoritmos de particiones separan los datos en un número prefijado de grupos. Cada uno de esos grupos se representa mediante un centroide, que es el punto cuya suma de distancias desde todos los datos del grupo a sí mismo es mínima [6] [7] [8]. En este trabajo nos centramos en los algoritmos de particiones.

Dentro de los algoritmos de particiones uno de los más conocidos y utilizados es el k-means [3] [8]. En este algoritmo se separan todos los datos en  $c$  grupos y se calculan los centroides de cada grupo. El objetivo es minimizar la suma de las distancias de cada dato a su centroide correspondiente.

$$J = \sum_{i=1}^c \sum_{x_k \in cluster_i} \|x_k - v_i\|_A^2$$

Este trabajo ha sido parcialmente financiado por el Ministerio de Educación, Cultura y Deporte mediante el programa José Castillejo para estancias de movilidad en el extranjero de jóvenes doctores. También ha sido parcialmente financiado por el Ministerio de Economía, Industria y Competitividad del Gobierno de España mediante el proyecto TIN2016-77356-P (AEI/FEDER, UE).

donde  $\|x\|_A = \sqrt{x^t A x}$  es cualquier norma asociada a un producto escalar.

Uno de los problemas que presenta el algoritmo k-means, así como muchos algoritmos de agrupamiento de particiones, es que no son capaces de manejar situaciones en las que los grupos de datos se encuentran solapados. En esos casos, los datos que se encuentran en la zona solapada entre dos o más grupos deberían pertenecer a todos esos grupos y no solo a uno de ellos.

Una de las maneras de solucionar este problema es utilizando la lógica difusa [10]. De este modo, cada uno de los datos puede pertenecer a más de un grupo, con diferente valor de pertenencia. Estos valores de pertenencia son números entre 0 y 1. El algoritmo Fuzzy Cluster Means (FCM) [1] extiende la idea del algoritmo k-means empleando la lógica difusa.

En el FCM, cada dato tiene una pertenencia total de 1, que reparte entre todos los grupos. De esta manera, un mismo dato puede pertenecer a todos los grupos existentes, siempre y cuando la suma de sus valores de pertenencia sea 1. El objetivo es minimizar la suma ponderada de las distancias de cada dato a todos los centroides. Los pesos de esta suma vienen dados por el valor de pertenencia de cada dato a cada grupo.

$$J = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|_A^2$$

Este algoritmo consigue solucionar el problema del solapamiento entre grupos. Sin embargo, cuando existen outliers entre los datos a clasificar, el FCM no es capaz de detectarlos y por ello sus resultados se ven distorsionados.

Para solucionar este problema, en este trabajo presentamos un nuevo algoritmo de agrupamiento que extiende el FCM, de tal forma que es capaz de detectar los datos que no pertenecen a los grupos naturales existentes en el conjunto de datos.

De la misma forma que el uso de los conjuntos difusos permite aportar nueva información al proceso de agrupamiento, en nuestra propuesta utilizamos una extensión de los conjuntos difusos: los conjuntos intervalo-valorados difusos. En este trabajo, utilizamos dichos conjuntos para cuantificar las pertenencias, por lo que cada dato va a pertenecer a todos los grupos con un valor de pertenencia que es un intervalo en  $[0,1]$ . Utilizamos la amplitud de dicho intervalo



para representar la seguridad que tenemos de que ese dato pertenezca a los grupos presentes en el dataset que estamos clasificando. De esta forma, si estamos totalmente seguros de que un dato pertenece a uno o varios de los grupos existentes, las pertenencias de dichos datos a todos los grupos tendrán amplitud 0. Por el contrario, si estamos totalmente seguros de que un dato no pertenece a ninguno de los grupos presentes, las pertenencias de ese dato a todos los grupos tendrán amplitud 1, que es el máximo permitido.

El resto de este trabajo está organizado de la siguiente forma: en la Sección II repasamos brevemente el algoritmo Fuzzy Cluster Means; en la Sección III explicamos en detalle el algoritmo que proponemos en este trabajo y en la Sección IV vemos cómo se comporta mediante el uso de varios ejemplos de datos. Finalmente, en la Sección V mostramos las conclusiones obtenidas.

## II. FCM

El Fuzzy Cluster Means (FCM) [1] es uno de los algoritmos de agrupamiento difuso más utilizados. Al utilizar conjuntos difusos, permite que cada uno de los datos pertenezca a más de un grupo al mismo tiempo. De hecho, basa su idea en que cada dato debe pertenecer a todos los grupos presentes con un grado de pertenencia dado. Estos grados de pertenencia son valores entre 0 y 1, de tal forma que la suma de los valores de pertenencia de cada dato a todos los grupos siempre sea 1.

Con esta premisa, el algoritmo FCM trata de minimizar la suma de distancias ponderadas de cada dato a todos los centroides, haciendo que los pesos de ponderación sean proporcionales al valor de pertenencia del dato a ese grupo.

$$J = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|_A^2$$

donde  $x_k$  es el  $k$ -ésimo dato a clasificar,  $v_i$  es el centroide del grupo  $i$ ,  $u_{ik}$  es el grado de pertenencia del dato  $k$  al grupo  $i$  y  $m$  es un valor real mayor que 1. Además, se deben cumplir tres restricciones:

- $u_{ik} \geq 0$ ,  $k = 1..n$ ,  $i = 1..c$
- $\sum_{k=1}^n u_{ik} > 0$ ,  $i = 1..c$
- $\sum_{i=1}^c u_{ik} = 1$ ,  $k = 1..n$

La solución a este problema es un proceso iterativo que comienza con unos centroides elegidos aleatoriamente. A partir de los centroides se pueden calcular los nuevos valores de pertenencia de cada dato a cada grupo:

$$u_{ik} = \left( \sum_{j=1}^c \left( \frac{\|x_k - v_j\|_A}{\|x_k - v_i\|_A} \right)^{2/(m-1)} \right)^{-1}$$

$k = 1..n$ ,  $i = 1..c$ . Y a partir de los valores de pertenencia se pueden calcular los nuevos centroides:

$$v_i = \frac{\sum_{k=1}^n (u_{ik})^m x_k}{\sum_{k=1}^n (u_{ik})^m}$$

$i = 1..c$ . El proceso termina cuando los cambios en los valores son suficientemente pequeños.

Uno de los problemas que presenta el algoritmo FCM se produce cuando el conjunto de datos a clasificar presenta ruido, o outliers. En estos casos, todos los datos se asignan a los diferentes grupos, por lo que los datos alejados pueden modificar erróneamente sus centroides. En la Figura 1 podemos ver un conjunto de datos marcados con asteriscos negros. Claramente podemos ver dos grupos de datos que se solapan y un dato que no pertenece a ninguno de los grupos. Marcados con círculos rojos se ven los centroides de los dos grupos detectados por el algoritmo FCM.

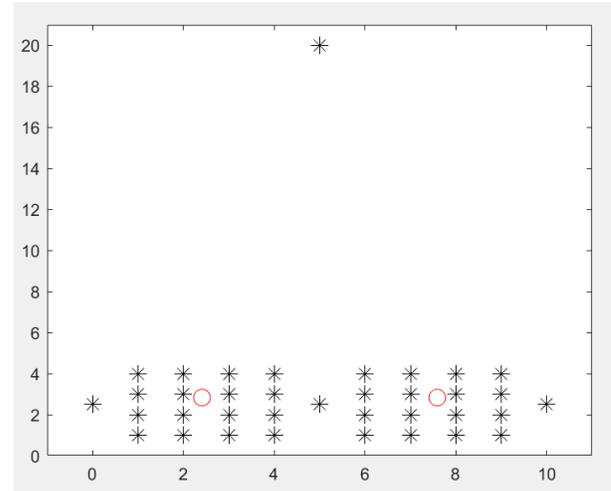


Figura 1. Ejecución del algoritmo FCM sobre un conjunto de datos con un outlier. Conjunto de datos a clasificar marcados con asteriscos negros. Centroides obtenidos por el FCM marcados con círculos rojos.

Los dos grupos de datos están centrados verticalmente en el punto 2.5. Sin embargo, como el dato situado en el punto (5, 20) pertenece a ambos grupos, los centroides se desplazan hacia arriba hasta el valor vertical 2.83.

Además, si analizamos los valores de pertenencia de cada dato a los dos grupos, vemos que el dato situado en el punto (5, 2.5) tiene un valor de pertenencia de 0.5 a cada uno de los grupos. Por su parte, el dato situado en el punto (5, 20) también tiene un valor de pertenencia de 0.5 a cada grupo. Por tanto, el algoritmo nos indica que ambos datos son iguales a la hora de formar los dos grupos. Sin embargo, observando la figura, vemos que uno de los dos datos pertenece a la zona solapada de los dos grupos mientras que el otro dato no pertenece a ninguno de los grupos.

A partir de este ejemplo, podemos afirmar que el algoritmo Fuzzy Cluster Means no funciona adecuadamente cuando en el conjunto de datos a clasificar hay datos que no pertenecen a ninguno de los grupos existentes.

## III. NUEVO ALGORITMO DE CLUSTERING INTERVALAR

En esta sección explicamos nuestra propuesta de algoritmo de agrupamiento. Su principal novedad es que hace uso de los conjuntos intervalo-valorados difusos para representar las pertenencias de los datos a cada cluster.

Llamamos  $L([0, 1])$  al conjunto de todos los subintervalos cerrados en  $[0, 1]$ , es decir,

$$L([0, 1]) = \{x = [\underline{x}, \bar{x}] \mid (\underline{x}, \bar{x}) \in [0, 1]^2 \text{ y } \underline{x} \leq \bar{x}\}$$

Un conjunto intervalo-valorado difuso  $Z$  en el universo  $U \neq \emptyset$  es una función  $Z : U \rightarrow L([0, 1])$ .

Una de las interpretaciones existentes de los conjuntos intervalo-valorado difusos, la cual utilizamos en este trabajo, es la siguiente: “el grado de pertenencia de un elemento al conjunto es un valor dentro del intervalo de pertenencia considerado. No conocemos exactamente el valor, por lo que proporcionamos sus extremos” [2].

Siguiendo esta idea, podemos asumir que la amplitud del intervalo representa la ignorancia que tenemos a la hora de asignar el valor de pertenencia del elemento al conjunto.

Aplicándolo sobre nuestro problema de agrupamiento, queremos que si el algoritmo está completamente seguro de que un dato pertenece a un grupo, entonces la amplitud de su intervalo de pertenencia será mínima. No importa si la pertenencia es  $[1, 1]$  a un grupo y  $[0, 0]$  a los demás, o si pertenece  $[0,5, 0,5]$  a dos grupos. Por el contrario, si el algoritmo no está seguro de que un dato pertenezca a los grupos que se han creado en los datos, entonces la amplitud de sus intervalos de pertenencia deberá ser mayor. En el caso extremo, si un dato parece no pertenecer a ninguno de los grupos existentes, los intervalos de pertenencia a todos los grupos pueden ser  $[0, 1]$ .

Por tanto, a diferencia del algoritmo Fuzzy Cluster Means, en nuestra propuesta la suma de los extremos inferiores y superiores de las pertenencias de un dato a todos los grupos tiene que ser un valor entre 2 y  $c$ , siendo  $c$  el número de grupos. En el caso en el que no existe ninguna duda sobre la pertenencia de los datos a los grupos, los extremos inferiores de todos los valores de pertenencia son iguales a los extremos superiores. Manteniendo la misma restricción que existía en el FCM, estos deben sumar 1, por lo que la suma total es 2. En el caso de que la duda sobre la pertenencia sea máxima, los intervalos de pertenencia a todos los grupos serán  $[0, 1]$ , por lo que la suma total será igual al número de grupos.

De forma análoga al k-means y al FCM, con este nuevo algoritmo queremos minimizar la suma ponderada de distancias entre cada dato y los centroides de cada grupo, utilizando como pesos los valores de pertenencia. En este caso, esos valores de pertenencia son intervalos. Cuando no existe duda sobre el valor de pertenencia, el extremo inferior y superior del intervalo son muy parecidos y representan el valor que debe tomar el peso. Por el contrario, cuando existe una gran duda de que un dato pertenezca a un grupo, no queremos que su información modifique en gran medida el valor del centroide, por lo que queremos que su peso sea pequeño. Al ser la amplitud del intervalo grande, eso significa que su extremo inferior tiene que ser pequeño. Por tanto, en ambos casos podemos utilizar un peso para la suma ponderada proporcional al extremo inferior del intervalo de pertenencia.

También es necesario restringir la suma total de las amplitudes de los intervalos de pertenencia. De no hacerlo, nuestro

sistema se minimizaría al decir que tenemos una duda máxima sobre la pertenencia de todos los datos existentes.

Por tanto, la función objetivo que queremos minimizar en nuestra propuesta es la siguiente:

$$J = \frac{1}{a} \sum_{k=1}^n \sum_{i=1}^c (\underline{u}_{ik})^m \|x_k - v_i\|_A^2 + \sum_{k=1}^n \sum_{i=1}^c (\bar{u}_{ik} - \underline{u}_{ik})^m$$

donde  $x_k$  es el  $k$ -ésimo dato a clasificar,  $v_i$  es el centroide del grupo  $i$ ,  $[\underline{u}_{ik}, \bar{u}_{ik}]$  es el intervalo de pertenencia del dato  $k$  al grupo  $i$  y  $m$  es un valor real mayor que 1.

El parámetro  $1/a$  permite ajustar la importancia relativa de los dos términos de la ecuación. Hay que tener en cuenta que ambos términos no tienen por que estar en la misma escala: el primer término depende de las distancias entre los datos y el segundo es siempre un valor entre 0 y 1. Mediante este parámetro podemos conseguir que la solución obtenida se parezca más a la obtenida por el FCM si hacemos que el segundo término tenga mucha importancia, o que la solución presente en general amplitudes muy grandes, si es el primer término el más importante.

Esta función está sujeta a las siguientes restricciones:

- Los intervalos tienen que estar bien formados.  $\bar{u}_{ik} \geq \underline{u}_{ik}$ ,  $k = 1..n$ ,  $i = 1..c$
- Todos los grupos tienen que tener por lo menos un dato con extremo inferior de pertenencia positivo.  $\sum_{k=1}^n \underline{u}_{ik} > 0$ ,  $i = 1..c$
- La suma de los extremos de las pertenencias de un dato a todos los grupos tiene que estar entre 2 y  $c$ .  $2 \geq \sum_{i=1}^c (\underline{u}_{ik} + \bar{u}_{ik}) \leq c$ ,  $k = 1..n$

Cuando el número de grupos es 2, esta función se puede minimizar utilizando multiplicadores de Lagrange. De esta forma, obtenemos un algoritmo iterativo análogo al FCM. A partir de una inicialización aleatoria, podemos actualizar los intervalos de pertenencia basándonos en los datos de los centroides.

$$\underline{u}_{ik} = \frac{2(2a)^{1/m-1}}{\|x_k - v_i\|^{2/m-1} \left[ c + 2(2a)^{1/m-1} \sum_{j=1}^c \frac{1}{\|x_k - v_j\|^{2/m-1}} \right]}$$

$$\bar{u}_{ik} = \frac{2 \left[ \|x_k - v_i\|^{2/m-1} + (2a)^{1/m-1} \right]}{\|x_k - v_i\|^{2/m-1} \left[ c + 2(2a)^{1/m-1} \sum_{j=1}^c \frac{1}{\|x_k - v_j\|^{2/m-1}} \right]}$$

para  $k = 1..n$ ,  $i = 1..c$ . A partir de los datos de los intervalos de pertenencia, podemos actualizar los centroides.

$$v_i = \frac{\sum_{k=1}^n (\underline{u}_{ik})^m x_k}{\sum_{k=1}^n (\underline{u}_{ik})^m}$$

para  $i = 1..c$ . El proceso termina cuando los cambios en los valores son suficientemente pequeños.

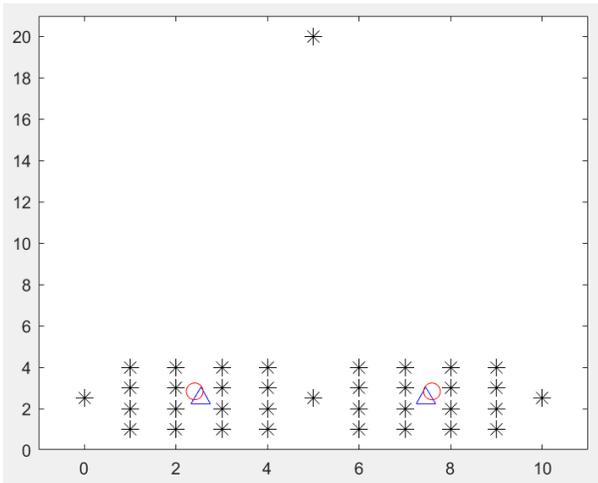


Figura 2. Ejecución del algoritmo propuesto y del FCM sobre un conjunto de datos con un outlier. Conjunto de datos a clasificar marcados con asteriscos negros. Centroides obtenidos por nuestro algoritmo marcados con triángulos azules. Centroides obtenidos por el FCM marcados con círculos rojos.

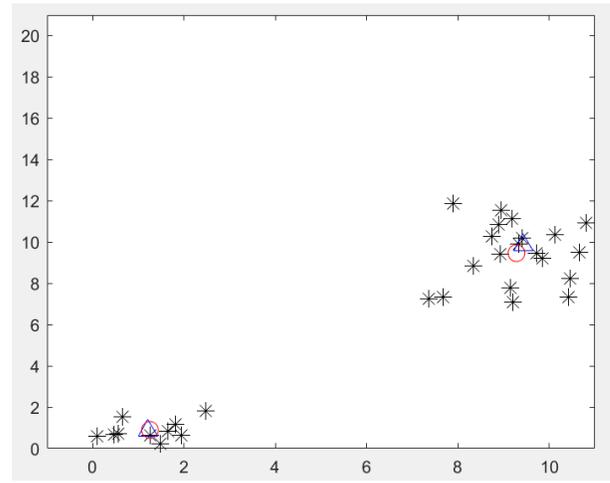


Figura 3. Ejecución del algoritmo propuesto y del FCM sobre un conjunto de datos sin outliers. Conjunto de datos a clasificar marcados con asteriscos negros. Centroides obtenidos por nuestro algoritmo marcados con triángulos azules. Centroides obtenidos por el FCM marcados con círculos rojos.

#### IV. EJEMPLOS NUMÉRICOS

En esta sección mostramos el comportamiento del algoritmo que hemos propuesto. Para poder visualizar los ejemplos con mayor simplicidad y que sean más fáciles de entender, en todos ellos utilizamos sólo dos dimensiones.

Comenzamos con el mismo ejemplo que hemos visto en la Figura 1. Como ya hemos comentado, el FCM no es capaz de resolver este ejemplo correctamente. Al aplicar nuestro algoritmo, los centroides obtenidos ya no se desplazan hacia arriba de donde deberían estar y se colocan en el centro real de los grupos existentes. En la Figura 2 hemos marcado con triángulos azules los centros obtenidos por nuestro algoritmo y con círculos rojos aquellos obtenidos por el FCM.

Si analizamos los intervalos de pertenencia resultantes de este ejemplo, el dato situado en la intersección de los dos grupos (punto (5, 2.5)) tiene pertenencia [0.3488, 0.6512] a cada uno de los grupos, con una amplitud de 0.3024. Por su parte, el dato outlier (punto (5, 20)) tiene pertenencia [0.0004, 0.9996] a cada uno de los grupos, con una amplitud de 0.9991. Podemos ver claramente como el algoritmo es capaz de identificar que estos dos datos no son iguales a la hora de hacer la clasificación. Al tener una amplitud tan grande el outlier, esto hace que casi no se tenga en cuenta a la hora de calcular los centroides, y por eso estos se sitúan en el centro geométrico del grupo correspondiente.

En la Figura 3 podemos ver un nuevo conjunto de datos y cómo se comportan sobre él nuestro algoritmo (centroides marcados con triángulos azules) y el FCM (centroides marcados con círculos rojos). Se puede comprobar que ambos algoritmos obtienen una solución muy similar.

Si a ese mismo conjunto de datos le añadimos tres outliers, entonces vemos que los dos algoritmos ya cambian su comportamiento. Esta nueva ejecución se puede ver en la Figura 4, siguiendo la misma leyenda.

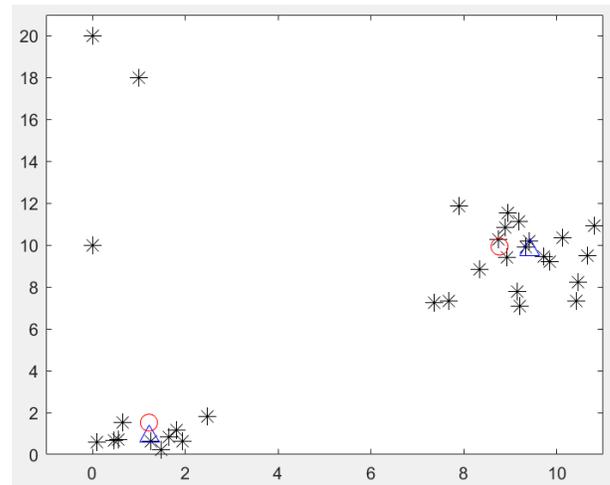


Figura 4. Conjunto de datos igual al de la figura 3 al que se le han añadido tres outliers en los puntos (0,20), (1,18) y (0,10). Ejecución del algoritmo propuesto y del FCM. Conjunto de datos a clasificar marcados con asteriscos negros. Centroides obtenidos por nuestro algoritmo marcados con triángulos azules. Centroides obtenidos por el FCM marcados con círculos rojos.

Como podemos comprobar visualmente, la adición de tres outliers casi no ha modificado los valores de los centroides obtenidos por nuestro algoritmo. Analíticamente, estos valores han pasado de ser

- Grupo1 → (1.2107, 0.8496)
- Grupo2 → (9.4268, 9.8496)

a valer

- Grupo1 → (1.2223, 0.8670)
- Grupo2 → (9.4149, 9.7710)

Sin embargo, en la ejecución del FCM los nuevos centroides se ven claramente influenciados por los outliers, y se desplazan hacia allí. El centroide del grupo 1 se desplaza hacia arriba y el centroide del grupo 2 lo hace hacia la izquierda. De esta forma, pasan de valer

- Grupo1  $\rightarrow$  (1.2531, 0.8985)
- Grupo2  $\rightarrow$  (9.2796, 9.4647)

a valer

- Grupo1  $\rightarrow$  (1.2181, 1.5217)
- Grupo2  $\rightarrow$  (8.7661, 9.9312)

Uno de los aspectos más importantes a la hora de aplicar nuestro algoritmo de agrupamiento es el ajuste del parámetro  $1/a$ . Este parámetro permite ajustar la amplitud de los intervalos de pertenencia. Si el parámetro  $1/a$  toma valores muy grandes, entonces el algoritmo obtiene soluciones donde las amplitudes de todas las pertenencias son grandes. Por el contrario, si el parámetro  $1/a$  toma valores pequeños, entonces el algoritmo encuentra soluciones donde las amplitudes de los intervalos de pertenencia son pequeñas. Para cada uno de los problemas es necesario ajustar este parámetro, para obtener las soluciones deseadas.

En la Figura 5 vemos un nuevo conjunto de datos marcado con asteriscos negros y tres pares de puntos que representan los centros obtenidos con tres valores del parámetro  $1/a$  distintos. Mediante cuadrados rojos los centros obtenidos cuando  $1/a = 1/0,0001$ , triángulos azules cuando  $1/a = 1/10000$  y círculos verdes cuando  $1/a = 1/1$ .

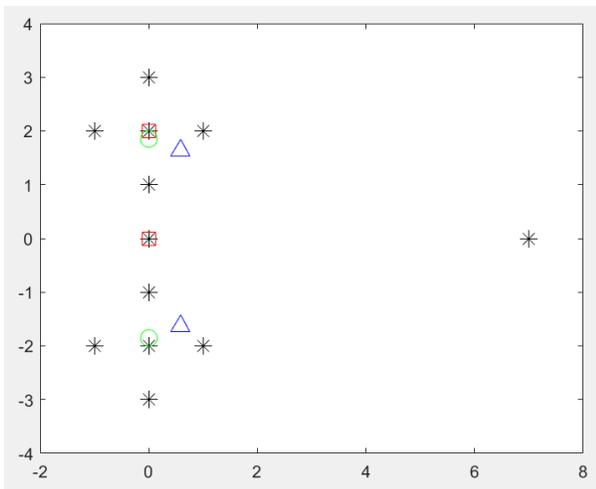


Figura 5. Conjunto de datos marcado mediante asteriscos negros. Centros obtenidos mediante el algoritmo propuesto cuando  $1/a = 1/0,0001$  (cuadrados rojos),  $1/a = 1/10000$  (triángulos azules) y  $1/a = 1/1$  (círculos verdes).

Como se puede observar, los resultados varían en gran medida dependiendo del valor del parámetro. En el Cuadro I se muestran los valores de los intervalos de pertenencia de cada dato a cada grupo. Cuando  $1/a = 1/0,0001$ , el algoritmo encuentra dos centroides aleatorios, cuyas pertenencias son  $[0, 0]$  y  $[1, 1]$  a los dos grupos. El resto de datos tienen una pertenencia de  $[0, 1]$  a los dos grupos, es decir, la máxima amplitud posible. En este ejemplo de ejecución, los datos elegidos para convertirse en centroides son el  $(0, 2)$  y el  $(0, 0)$ . Por el contrario, cuando  $1/a = 1/10000$ , todos los intervalos de pertenencia tienen amplitud 0 y, por ello, pueden ser considerados como valores puntuales. En este caso, el resultado obtenido es muy parecido al obtenido por el FCM.

Por último, el caso en el que  $1/a = 1/1$  muestra un ejemplo de buen balance entre los dos extremos. En este caso, los datos que están muy cercanos a algún centroide y que, por lo tanto, el algoritmo está seguro de su pertenencia a los grupos existentes, tienen intervalos de pertenencia con amplitudes pequeñas. El dato situado en el punto  $(0, 0)$ , justo en la intersección de los dos grupos, tiene una amplitud mayor que el resto de datos, puesto que está más alejado de los centroides, pero mucho menor que el dato  $(7, 0)$ , que no debería pertenecer a ninguno de los dos grupos. Este dato tiene una pertenencia de  $[0, 0015, 0, 9985]$  a ambos grupos, casi la máxima posible.

Por tanto, es muy importante ajustar el parámetro  $1/a$ , que balancea la importancia relativa de las distancias entre los datos y los centroides con las amplitudes de las pertenencias. Según nuestras pruebas hechas sobre varios conjuntos de datos, un valor que funciona en la mayoría de los casos es cuando  $a$  toma el valor del percentil 10 o 15 de las distancias entre los datos del conjunto de datos.

## V. CONCLUSIONES

En este trabajo hemos presentado una extensión del algoritmo Fuzzy Cluster Means. Mediante nuestra propuesta, utilizamos una extensión de los conjuntos difusos, los conjuntos intervalo-valorados difusos, para permitir que el algoritmo detecte los datos considerados outliers y que estos no interfieran en el proceso de agrupamiento del resto de datos. Mediante varios ejemplos ilustrativos hemos comprobado que el algoritmo se comporta de manera correcta, tanto cuando existen outliers como cuando no. Además, hemos comprobado que es muy importante la elección de un buen valor para el parámetro que pondera los dos términos de la función objetivo, ya que este parámetro permite una variedad total entre soluciones con la máxima y la mínima amplitud en las pertenencias de todos los datos a todos los grupos.

## REFERENCIAS

- [1] J.C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms" Plenum Press, 1981.
- [2] H. Bustince, E. Barrenechea, M. Pagola, J. Fernandez, Z. Xu, B. Bedregal, J. Montero, H. Hagrais, F. Herrera, B. De Baets, "A historical account of types of fuzzy sets and their relationships" IEEE Transactions on Fuzzy Systems 24, 179-194, 2016.
- [3] E.W. Forgy, "Cluster analysis of multivariate data: efficiency versus interpretability of classifications", Biometrics 21, 768-769, 1965.
- [4] A.K. Jain, M.N. Murty, P.J. Flynn, "Data clustering: A review" ACM Computing Surveys 31, 264-323, 1999.
- [5] S.C. Johnson, "Hierarchical clustering schemes" Psychometrika 32, 241-254, 1967.
- [6] L. Faufman, P.J. Rousseeuw, "CLustering by means of Medoids", in Statistical Data Analysis Based on the  $L_1$ -Norm and Related Methods, edited by Y. Dodge, North-Holland, 405-416, 1987.
- [7] S.P. Lloyd, "Least square quantization in PCM", IEEE Transactions on Information Theory 28, 129-137, 1982.
- [8] J.B. MacQueen, "Some Methods for Classification and Analysis of Multivariate Observations", Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability 1, 281-297, 1967.
- [9] J.H. Ward Jr., "Hierarchical Grouping to Optimize an Objective Function", Journal of the American Statistical Association, 58, 236-244, 1963.
- [10] L.A. Zadeh, "Fuzzy sets", Information and Control 8, 338-353, 1965.



Cuadro I

RESULTADOS DE LOS INTERVALOS DE PERTENENCIA OBTENIDOS POR EL ALGORITMO PROPUESTO SOBRE EL CONJUNTO DE DATOS DE LA FIGURA 5. EN CADA FILA SE MUESTRA LA INFORMACIÓN REFERENTE A UN DATO. PARA ÉL SE INDICAN LOS INTERVALOS DE PERTENENCIA A LOS DOS GRUPOS EXISTENTES, CUANDO EJECUTAMOS EL ALGORITMO CON DIFERENTES VALORES DEL PARÁMETRO  $1/a$ :  $1/0,0001$ ,  $1/10000$  Y  $1/1$ .

Dato	$1/a = 1/0,0001$		$1/a = 1/10000$		$1/a = 1/1$	
	Grupo 1	Grupo 2	Grupo 1	Grupo 2	Grupo 1	Grupo 2
(-1, -2)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.9725, 0.9725]	[0.0275, 0.0275]	[0.7882, 0.9967]	[0.0033, 0.2118]
(0, -1)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.9897, 0.9897]	[0.0103, 0.0103]	[0.8775, 0.9930]	[0.0070, 0.1225]
(0, -2)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.9988, 0.9988]	[0.0012, 0.0012]	[0.9999, 1.0000]	[0.0000, 0.0001]
(0, -3)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.9899, 0.9899]	[0.0101, 0.0101]	[0.6956, 0.9978]	[0.0022, 0.3044]
(1, -2)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.9995, 0.9995]	[0.0005, 0.0005]	[0.7925, 0.9967]	[0.0033, 0.2075]
(-1, 2)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.0275, 0.0275]	[0.9725, 0.9725]	[0.0033, 0.2118]	[0.7882, 0.9967]
(0, 1)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.0103, 0.0103]	[0.9897, 0.9897]	[0.0070, 0.1225]	[0.8775, 0.9930]
(0, 2)	[1.0000, 1.0000]	[0.0000, 0.0000]	[0.0012, 0.0012]	[0.9988, 0.9988]	[0.0000, 0.0001]	[0.9999, 1.0000]
(0, 3)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.0101, 0.0101]	[0.9899, 0.9899]	[0.0022, 0.3044]	[0.6956, 0.9978]
(1, 2)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.0005, 0.0005]	[0.9995, 0.9995]	[0.0033, 0.2075]	[0.7925, 0.9967]
(0, 0)	[0.0000, 0.0000]	[1.0000, 1.0000]	[0.5000, 0.5000]	[0.5000, 0.5000]	[0.2024, 0.7976]	[0.2024, 0.7976]
(7, 0)	[0.0000, 1.0000]	[0.0000, 1.0000]	[0.5000, 0.5000]	[0.5000, 0.5000]	[0.0015, 0.9985]	[0.0015, 0.9985]

# Assessing the performance of bipolar classifiers in three-class problems

1<sup>st</sup> Guillermo Villarino

Facultad de Estudios Estadísticos  
Universidad Complutense de Madrid  
Madrid, Spain  
gvillari@ucm.es

2<sup>nd</sup> Daniel Gómez

Facultad de Estudios Estadísticos  
Universidad Complutense de Madrid  
Madrid, Spain  
dagomez@estad.ucm.es

3<sup>rd</sup> J. Tinguaro Rodríguez

Facultad de Ciencias Matemáticas  
Universidad Complutense de Madrid  
Madrid, Spain  
jtrodrig@mat.ucm.es

## Abstract

In the context of supervised classification, several aspects already exist which need to be improved regarding the decision making step that any classifier passes through. Before providing the final assignment, many classification algorithms produce a soft score (either a probability, a fuzzy degree, a possibility, a cost, etc.) assessing the strength of the association between each item to be classified and each class. Usually, the final decision or classification step of these algorithms consists on assigning the item to the class with the highest soft score, a method typically known as the *maximum rule*. However, this procedure does not always take advantage of all the information contained in such soft scores. In other words, the final classification step of many algorithms may be improved through alternative procedures more sensible to the available soft information that the mentioned maximum rule.

To this aim, in this paper we propose a general bipolar approach that enables learning how to take advantage of the soft information provided by many classification algorithms in order to enhance the generalization power and accuracy of the classifiers. To show the suitability of the proposed approach, we also present some computational experiences for three-class classification problems, in which its application to some well-known classifiers as random forest and neural networks produce some improvements in performance.

**Index Terms**—Supervised classification models, bipolar models, Machine learning, Soft information

## I. INTRODUCTION

One of the most important topics in data science is classification, and particularly supervised classification tasks. In the literature, there exist a huge diversity of supervised classification algorithms, approaches and applications, depending on the specific tasks, type of data, characteristics or efficiency [7], [8]. Typically, in a supervised classification context the main aim is to be able to classify a set of items into classes based on a training sample or dataset that provides examples of association between items and classes, and that is used to train the classifiers in order to adequately generalize the observed associations, that is, to fit the classification models to the observed data.

Following the ideas presented in [12]–[15], in [17] classical supervised algorithms as CART [2], Random Forest (RF) [3] and Neural Networks [11], [16] were modelled as probabilistic classifiers, providing soft probabilistic assessments of the association of items with classes. In a second step, a bipolar probabilistic representation framework was developed by allowing some opposition or dissimilarity relationships between the classes to be introduced. In a third step, the more convenient structure of dissimilarity relationships was learned through an evolutionary algorithm. This more expressive representational model and the associated learning process permitted to improve the classification performance of the original classifiers in a binary classification context. In this paper we extend these results by addressing three-class classification problems instead of binary ones.

Moreover, in [18] we proposed a replication + aggregation scheme to obtain a fuzzy classifier from a probabilistic one as a robustness enhancing pre-process that permits developing a fuzzy bipolar model from any soft classification algorithm. The experimental results were also carried out in a binary classification context.

The remainder of the paper is organized as follows: Section II describes the preliminary concepts we will use along the work, including the differences between crisp and probabilistic classifiers, as well as some specific concepts regarding accuracy measures and Genetic Algorithms (GAs). Then, in Section III, we present the main idea of bipolar knowledge representation and the complete two-stage (learning and aggregating) process for constructing a bipolar classifier from a soft supervised one. Finally, the experimental framework along with the respective analysis of the results are presented in Sections IV and V. We summarize the paper with the main concluding remarks in Section VI.

## II. PRELIMINARIES

In this preliminary section, we introduce some concepts for a better understanding of the paper. We firstly introduce the main concepts of crisp and probabilistic classifiers as well as their differences and relationships to motivate one of the principal contributions of this paper: the importance of modelling the soft information of a classifier before making the final decision in a classification task.

### A. Crisp and probabilistic classifiers

Let us denote by  $\{C_1, \dots, C_k\}$  the set classes of a classification problem, and by  $X = \{x_1, \dots, x_n\}$  the set of items that



has to be classified.

As we have pointed in the introduction, many classification users only takes into account the final output of the classification task. This is probably because they are only interested in the final solution provided by the classifier. This is the reason why in a general way, the classifiers are usually viewed as functions

$$C : X \longrightarrow \{C_1, \dots, C_k\}, \quad (1)$$

that is, a procedure to assign one of the available classes to each of the items being classified.

Nevertheless, the classification process goes through many steps before to arrive to the final assignment, and it is in the intermediate steps that soft information usually appear as a natural way to model the information and the evidence being obtained. Particularly, it is very common that classification algorithms manage soft information for each item  $x \in X$  about the probability that  $x$  belongs to each of the different classes, or in fuzzy classification models about the degree of membership of the item  $x$  in the set of classes.

Taking into account these considerations, in [17] we distinguished between crisp (classical) and probabilistic classifiers. A probabilistic classifier can be viewed as a function

$$C_P : X \longrightarrow [0, 1]^k, \quad (2)$$

that assigns to each item  $x$  its probability of belonging to each of the available classes. Obviously, for any  $x \in X$  it has to hold that  $\sum_{i=1}^k (C_P(x))_i = 1$  because of the additivity of probability. We would like to remark that many classification algorithms (as for example neural networks, random forest or decision trees) could be viewed as probabilistic classifiers if we just look at the soft information provided by the algorithms before making the final decision or crisp assignment.

### III. PROBABILISTIC BIPOLAR MODEL

This section is devoted to present the underlying ideas of bipolar knowledge representation. Firstly, it merits to be stressed that the concept of dissimilarity assumes that the available classes are related through a certain opposition or dissimilarity structure informing of which classes provide negative evidence against the others. This dissimilar structure can be modelled through a dissimilarity matrix  $D$ , which contains the degree of dissimilarity for any pair of classes. Obviously, the main diagonal has to be composed by zero values.

It is clear that the dissimilarity matrix  $D$  plays a crucial role in this classification scheme since it determines how the negative evidence is derived from the initial evidence for each class. As a consequence, the performance of the resulting crisp classifier, as well as the effect of incorporating the bipolar representation framework and the aggregation method, are absolutely dependent on the choice of the matrix  $D$ .

Figure 3 shows a flow diagram of the proposed decision making stage, including the genetic search of the dissimilarity structure and its application to the test set.

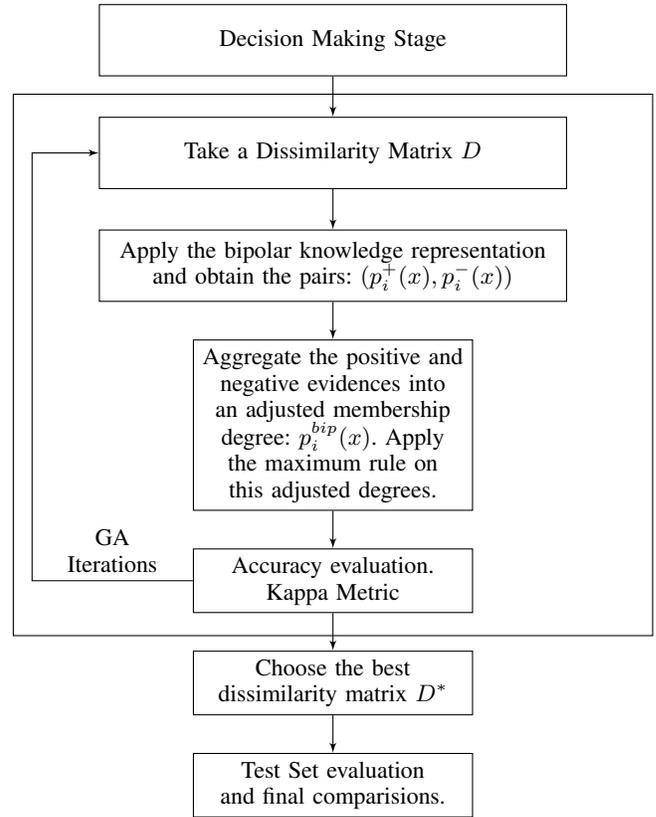


Fig. 1. Flow diagram of the proposed Decision Making Stage.

#### A. Learning the dissimilarity matrix

Ideally, in real situations the adequate structure of dissimilarity between classes should be proposed by application domain experts based on his knowledge. However, in many cases it may be more practical to obtain the matrix  $D$  through a learning process carried out once the base soft classifier has been trained. When this learning process is driven by a measure of performance focused on the generalization accuracy of the adjusted crisp classifier, the resulting matrix tends to fix some of the misassignments committed by the base classifier on the training sample, hopefully also improving its predictive accuracy on new queries or a test sample. Therefore, this learning approach allows that any probabilistic classifier may benefit from introducing a dissimilarity structure in the set of classes, aiding the decision rule of the classifiers to better adapt to the specific features of each dataset or application context.

Here we propose that the learning process of the dissimilarity matrix  $D$  is performed by means of a genetic algorithm (GA). The specific parameters of the applied GA are given in Section IV-C.

#### B. Obtaining the paired structure $(p^+, p^-)$

In this section we show the application of the dissimilarity matrix already learned by the GA to obtain the paired structure containing the positive and negative evidences.

To do so, we depart from the soft information (estimated probabilities) given by the base algorithm for an item  $x$ ,  $p_i(x) = p_i^+(x)$ , treating it as our positive probability of class  $C_i$  membership. Then, we apply the bipolar knowledge representation approach to get the negative evidence in the following way:

$$p_i^-(x) = \sum_{j \neq i} d_{ij} p_j^+(x) = \sum_{j=1}^k d_{ij} p_j^+(x) = D_i p^+(x), \quad (3)$$

Once the bipolar paired structure has been obtained, one of the possibilities we have is to aggregate this positive and negative evidences into a bipolar adjusted degree of evidence by applying any kind of aggregation operator.

Let us stress this is only one among the wide spectrum of possibilities for dealing with paired structures.

### C. Aggregating bipolar evidence: the additive and logistic cases

Let us now address the question of how to aggregate, for a given class  $C_i$  and an item  $x$ , the pair of positive and negative evidence degrees  $p_i^+(x)$  and  $p_i^-(x)$  in order to obtain a single adjusted degree  $p_i^{adj}(x)$ . Obviously, different aggregation choices will lead to different adjusted classifiers. In this work we have studied two different kinds of aggregation, that are defined below.

Let  $p_i^+(x)$ ,  $p_i^-(x)$  be the positive and negative probabilities of item  $x$  into class  $C_i$ . The additive adjusted degree of  $x$  into class  $C_i$  is defined as

$$p_i^{add}(x) = \max\{0, p_i^+(x) - p_i^-(x)\}. \quad (4)$$

Notice that the previous definition can be interpreted as the Lukasiewicz t-norm  $W(a, b) = \max\{a + b - 1, 0\}$  of the positive and non-negative degrees, that is,  $p_i^{add}(x) = W(p_i^+(x), n(p_i^-(x)))$ , where  $n$  stands for the standard negation  $n(a) = 1 - a$ . In this way, the positive evidence  $p_i^+(x)$  initially provided by the soft classifier is adjusted by subtracting from it the negative evidence  $p_i^-(x)$ . Particularly, the initial degrees are not modified when no class is dissimilar to  $C_i$ , that is, when  $D_i = 0$ .

Thus, an adjusted degree  $p_i^{add}(x) > 0$  represents the existence of a positive gap between the support for class  $C_i$  and the support for class  $dC_i$ , that is, for the classes considered dissimilar to  $C_i$ . In this situation, the strength of the association of item  $x$  with class  $C_i$  may have been reduced from its initial assessment, but it is still perfectly possible that item  $x$  is finally assigned to  $C_i$ . On the other hand, a zero value of  $p_i^{add}(x)$  represents a situation in which there exist more evidence for the dissimilar class  $dC_i$  than for  $C_i$ , and thus the adjusted classifier should not assign the item to class  $C_i$ .

In the following definition, we propose an alternative way to aggregate the positive and negative information into a single adjusted degree.

Let  $p_i^+(x)$ ,  $p_i^-(x)$  be the positive and negative evidence degrees of item  $x$  into class  $C_i$ . The logistic adjusted membership degree of  $x$  into class  $C_i$  is defined as

$$p_i^{log}(x) = \begin{cases} 1 - e^{-\frac{p_i^+(x)}{p_i^-(x)}} & \text{if } p_i^-(x) > 0 \\ 1 & \text{otherwise} \end{cases} \quad (5)$$

Unlike the additive logic of the previous aggregation, this logistic aggregation focuses on the ratio between positive and negative information, adjusting it to range in the  $[0, 1]$  interval through a logistic transformation. This permits a somehow more flexible behaviour of the adjusted degrees, in the sense that the choice of the dissimilarity matrix  $D$  may have an even greater influence in the adjustment of the initial positive evidence provided by the base soft classifier, up to the point that class  $p_i^{log}(x) = 1$  whenever no evidence is gathered for the dissimilar class  $dC_i$ , that is, when  $p_i^-(x) = 0$ .

As mentioned above, once one of these two aggregation methods has been applied and the adjusted degrees  $p_i^{adj}(x)$  has been obtained for each class (either  $p_i^{adj}(x) = p_i^{add}(x)$  or  $p_i^{adj}(x) = p_i^{log}(x)$ ), the final decision on the classification of item  $x$  is made by applying the maximum rule to such adjusted degrees. Therefore, the item  $x$  is finally assigned to the class  $C_h$  with a maximum adjusted degree  $p_h^{adj}(x)$ , that is,  $h = \arg \max_{i \in \{1, \dots, k\}} p_i^{adj}(x)$ .

## IV. EXPERIMENTAL FRAMEWORK

This section is devoted to present a computational experience aimed to assess the performance of our dissimilarity - based bipolar knowledge representation approaches (additive and logistic) when applied on recognized classifiers such as Random Forest [3] and Neural Networks [11], [16].

### A. Experimental setting details

As just mentioned, the base classifiers used in this experiment are Random Forest (RF) and Neural Networks (NNet). This experience is designed to compare the benchmark performance of these classifiers with those obtained from the later ones by means of the proposed dissimilarity learning process and the additive and logistic adjustments.

The results for each classifier in each experiment will be obtained following a 5-fold cross validation scheme for each dataset. In each folder, that is, for each training set, the optimal base classifier parametric configuration is approximated using a grid  $P$  on the space of parameters of the algorithms considered. In order to evaluate the performance of each specific parametric configuration  $p \in P$ , 25 bootstrap samples of the training set are generated, in such a way that the base classifiers are fit to each of these bootstrap samples and then tested on a hold-out sample (composed by the non selected instances in the bootstrapping process) using the kappa statistic.

At each folder, the genetic dissimilarity learning process is carried out departing from the vectors of estimated probabilities  $p(x)$  of the items  $x$  in the training sample in the way shown in III.

The train and test performance measures of each of the 3 classifiers in each dataset considered in each experiment are



Id.	Data-set	#Ex.	#Atts.	(R/I/N)
Aut	Autos	159	25	(15/0/10)
Car	Car	159	25	(15/0/10)
Wnq	Winequality-red	1599	11	(11/0/0)
Pen	Penbased	10992	16	(0/16/0)
Pag	Page-blocks	5472	10	(4/6/0)
Der	Dermatology	366	34	(0/34/0)
Eco	ecoli	336	7	(7/0/0)
Fla	flare	1066	25	(15/0/10)
Gla	Glass	214	9	(9/0/0)
Shu	Shuttle	2175	9	(0/9/10)
Yea	Yeast	1484	8	(8/0/0)
Lin	Lymphography	148	18	(3/0/15)
Bal	Balance	625	4	(4/0/0)
Win	Wine	178	13	(13/0/0)
Nty	Newthyroid	215	5	(4/1/0)
Hay	Hayes-Roth	160	4	(0/4/0)
Con	Contraceptive	1473	9	(6/0/3)
Thy	Thyroid	720	21	(6/0/15)

TABLE I

SUMMARY DESCRIPTION FOR THE EMPLOYED DATASETS.

finally computed by respectively averaging the train and test accuracy rates of the  $F = 5$  different folders.

### B. Data sets

We have selected a benchmark of 18 datasets from the KEEL dataset repository [1]. Particularly, we have used the 5-folder cross-validation datasets provided by KEEL in the different experiments. Table I summarizes the properties of the selected datasets, showing for each dataset the number of examples (#Ex.), the number of attributes (#Atts.) and type (Real/Integer/Natural) To transform multi-class datasets into three-class ones, we have taken as class  $C_0$  and  $C_1$  the originals closest to 20% of instances and as class  $C_2$  the union of the remainder classes.

### C. Genetic algorithm details

Finally, regarding the GA used at the evolutionary tuning of the dissimilarity structures, we have used the default GA for real-coded chromosomes implemented in the *genalg* R package. It is a standard GA, with usual crossover and mutation operators, the details of which can be consulted at [20]. The GA has been run with the following configuration, that provided satisfying solutions in a feasible amount of time:

- Population Size: 50 individuals.
- Number of iterations: 20
- Mutation Chance: 0.01.
- Elitism: About 20% of the population size.

Let us note at this point that we have tried a more complex configuration for the GA used in number of iterations, specifically we have used a 40 iterations and 100 individuals with no improvements.

### D. Statistical test for performance comparison

In this paper, we use some hypothesis validation techniques in order to give statistical support to the analysis of the results.

Specifically, we employ the Wilcoxon rank test [19] as a non-parametric statistical procedure for making pairwise comparisons between two algorithms. For multiple comparisons,

we use the Friedman aligned ranks test, which is recommended in the literature [4], [5] to detect statistical differences among a group of results. Finally, the Holm post-hoc test [6] has been used to find the algorithms that reject the equality hypothesis with respect to a selected control method. A complete description of these tests, with many considerations and recommendations and even the software used to run this analysis can be found on the website <http://sci2s.ugr.es/sicdm/>.

## V. EXPERIMENTAL RESULTS

This section is aimed to present the results of the computational experience described above, and carried out in order to study the capacity of enhancement of our bipolar adjusted classifiers with respect to the reference base classifier to which the proposed final decision tuning method is applied.

Results are grouped, for each base algorithm, in pairs for training and test, where the best global result for each considered dataset is stressed in **bold-face**. None is stressed in case of ties.

The experimental study has been obtained using R Software. Specifically, we used the *caret* package [21] for the classifiers training, fitting them through the underlying classical packages *random forest* and *nnet*, and finally the *genalg* package [20] to assess the GA.

For performing all the analysis presented in this paper we have used a computer AMD A10-6700 3.94GHz, 8GB RAM, Windows 8.1.

We can observe from the results of tables II and III the general good behaviour of the bipolar tuning method, at least regarding one of the bipolar adjustment methods, since it allows the improvement in performance of the reference algorithms.

	RF					
	Ref		bipAdd		bipLog	
	Train	Test	Train	Test	Train	Test
Aut	1.000	0.716	1.000	<b>0.719</b>	1.000	0.706
Car	0.996	<b>0.867</b>	1.000	0.854	1.000	0.857
Wnq	1.000	0.515	1.000	0.489	1.000	<b>0.525</b>
Pen	1.000	<b>0.903</b>	1.000	0.895	1.000	0.892
Pag	1.000	0.831	1.000	<b>0.832</b>	1.000	<b>0.832</b>
Der	1.000	<b>0.995</b>	1.000	0.993	1.000	0.992
Eco	1.000	0.758	1.000	<b>0.775</b>	1.000	0.764
Fla	0.796	0.783	0.805	<b>0.787</b>	0.807	0.784
Gla	1.000	0.672	1.000	0.658	1.000	<b>0.677</b>
Shu	1.000	<b>0.996</b>	1.000	<b>0.996</b>	1.000	0.995
Yea	1.000	0.377	1.000	0.366	1.000	<b>0.378</b>
Lin	0.981	0.672	0.996	0.675	0.996	<b>0.710</b>
Bal	0.612	<b>0.556</b>	0.615	0.523	0.617	0.513
Win	1.000	<b>0.979</b>	1.000	0.954	1.000	0.973
Nty	1.000	<b>0.935</b>	1.000	0.912	1.000	0.895
Hay	0.885	0.703	0.886	<b>0.715</b>	0.886	<b>0.715</b>
Con	0.788	0.280	0.807	<b>0.286</b>	0.807	0.279
Thy	1.000	0.895	1.000	<b>0.897</b>	1.000	0.891
Mean	0.948	<b>0.746</b>	0.950	0.740	0.951	0.743

TABLE II

RESULTS IN TRAIN AND TEST ACHIEVED BY THE GENETIC BIPOLAR APPROACHES APPLIED TO THE RF ALGORITHM.

Regarding the bipolar method applied to the RF classifier, in Table II we show the results and the following brief description of its behaviour.

- There is no improvement by kappa means when comparing the additive bipolar model against reference.
- The additive bipolar classifier outperforms the classification of the remainder approaches in 8 out of 18 datasets and the logistic one does so in 6 of them.
- Reference wins in 6 out of 18 datasets.
- There is a tie between the additive bipolar approach and the reference in the Shuttle dataset.

Thus we can see that we have reached improvements or ties in 12 out of 18 datasets when comparing. It is important to note the variable behaviour of the additive bipolar method in this case. Despite being the winner method in number of datasets, we can see that its mean is not the best because of the lower kappa value obtained in several of the remainder datasets.

	Ref		Nnet bipAdd		bipLog	
	Train	Test	Train	Test	Train	Test
	Aut	0.504	0.382	0.533	<b>0.385</b>	0.532
Car	1.000	0.997	1.000	0.997	1.000	0.997
Wnq	0.359	0.341	0.399	<b>0.356</b>	0.399	<b>0.356</b>
Pen	0.954	0.855	0.964	<b>0.866</b>	0.966	0.856
Pag	0.853	0.753	0.874	0.755	0.887	<b>0.774</b>
Der	1.000	0.987	1.000	<b>0.991</b>	1.000	<b>0.991</b>
Eco	0.753	<b>0.697</b>	0.779	0.680	0.777	0.688
Fla	0.785	<b>0.788</b>	0.794	0.782	0.795	0.777
Gla	0.660	0.507	0.688	<b>0.517</b>	0.687	0.513
Shu	0.991	0.976	0.993	<b>0.977</b>	0.994	<b>0.977</b>
Yea	0.440	0.360	0.473	0.379	0.473	<b>0.381</b>
Lin	0.896	0.667	0.922	0.671	0.925	<b>0.678</b>
BAl	0.600	0.586	0.603	0.562	0.603	<b>0.563</b>
Win	0.945	0.911	0.959	<b>0.915</b>	0.960	0.901
Nty	0.986	0.957	0.995	0.957	0.997	0.957
Hay	0.811	<b>0.615</b>	0.850	0.600	0.845	0.588
Con	0.356	0.334	0.383	0.336	0.383	<b>0.338</b>
Thy	0.859	0.738	0.904	0.770	0.925	<b>0.803</b>
Mean	0.764	0.692	0.784	0.694	0.786	<b>0.696</b>

TABLE III

RESULTS IN TRAIN AND TEST ACHIEVED BY THE GENETIC BIPOLAR APPROACHES APPLIED TO THE NNET ALGORITHM.

Considering the NNet classifier, the bipolar method reaches the results shown in Table III that could be interpreted as follows:

- There is an improvement by kappa means of 0.004 when comparing the logistic bipolar model against reference, being of 0.002 in case of the additive one.
- Both additive and logistic bipolar classifiers outperform the classification of the remainder approaches in 7 and 10 out of 18 datasets respectively.
- Reference wins in 3 out of 18 datasets.
- There two ties in these results.

On balance we have reached improvements or ties in 14 out of 18 datasets when comparing the bipolar approaches against the reference.

In order to detect significant differences among the results of the different approaches, we carry out the Friedman aligned rank test. This test obtains a low p-value for all the three algorithms, which implies that there are significant differences between the results provided by each method.

For this reason, we can apply a post-hoc test to compare our methodology against the remaining approaches. Specifically, a Holm test is applied using the best approach (the one with lower ranking) as control method and computing the adjusted p-value (APV) for the one with the highest ranking.

Obviously, it would be desirable for the reference to reach the highest or, at least, not the lowest ranking since it is usually associated with worse results.

Algorithm	Rank RF	Rank NNet
"Ref"	22.22	31.5
"BipAdd"	31.83	26.44
"BipLog"	28.44	24.55
p-val	0.00097	0.000913
APV	<b>0.1336</b>	<b>0.371</b>

TABLE IV

AVERAGE RANKINGS OF THE ALGORITHMS (ALIGNED FRIEDMAN), ASSOCIATED P-VALUES AND HOLM TEST APV FOR EACH ALGORITHM WITH THE MAX AGGREGATION.

Table IV, reflects that there are statistical significant differences between the three classifiers for both RF and NNet algorithms. However, in case of RF this differences and the respective statistical analysis should be carefully interpreted because of the lower ranking value obtained by the reference algorithm. In fact, the reference (RF without applying any bipolar approach) seems to reach the best results regarding the Friedman aligned rank test in spite of not being the best in number of datasets outperformed. Therefore there is no statistical evidence of the superiority of any method compared in case of RF.

Regarding the base Nnet classifier, Table IV shows the superiority of both bipolar approaches in ranking values, however the Holm post-hoc test reflects that there is not enough evidence to ensure that both bipolar approaches outperform the reference.

Comparison	$R^+$	$R^-$	p-val
RFbipAdd vs. RFRef	115.0	56.0	0.1913
RFbipLog vs. RFRef	100.0	71.0	0.5135
NNetbipAdd vs. NNetRef	100.0	53.0	0.2559
NNetbipLog vs. NNetRef	95.0	58.0	0.3684

TABLE V

WILCOXON TEST TO COMPARE THE BIPOLAR TUNING APPROACHES ( $R^+$ ) AGAINST THE BASE CLASSIFIER ( $R^-$ ).

The statistical analysis of the pairwise comparisons of methods, which is carried out by means of a Wilcoxon test, Table V, reflects the weak superiority of the proposed methodology when it is applied to the RF and Nnet algorithms with not so high p-values in case of additive bipolar model. Again, the application of the methodology on the RF and NNet algorithm does not reach significant improvements.

## VI. DISCUSSION AND FINAL REMARKS

In this paper we have studied the extension of probabilistic supervised classifiers into a bipolar knowledge representation framework by means of the introduction of a dissimilarity



structure in the set of classes. These structures enable considering different opposition or dissimilarity relationships between the available classes, that otherwise are by default considered as independent, unrelated objects. These relationships provide further information of the underlying structure of the classification problems being addressed, which can be used at the final decision or classification stage to better exploit the soft scores provided by any classifier to assess the association between each item and each class. Therefore, the introduction of dissimilarity structures may allow to strengthen the adaptation of the classifiers to each specific application context, in which classes acquire a particular semantics, thus also improving the classifier performance.

In this sense, the proposed approach can be understood as a general post processing method to fine tune the maximum decision rule usually applied to make the decision on the class assignment of each item to be classified.

To study the feasibility of the proposed approach, and particularly to remark that it can be applied to any soft classifier despite how it is obtained, we have applied it to two of the most powerful supervised classifiers, random forests and artificial neural networks. A rigorous and extensive computational experience has been conducted to analyse whether the proposed additive and logistic bipolar approaches enabled a statistically significant improvement of the base probabilistic classifiers.

Along this experimental study, we have reached several lessons learned:

- The bipolar framework improved the results of the two base machine learning algorithms considered in this work in number of datasets outperformed.
- Both the additive and logistic adjustment methods did not significantly outperform the results of the base classifier. However, they reached not so high p-values in the Wilcoxon test, specially the additive one.
- Comparing both the additive and the logistic proposed classifiers, we found there is no clear winner. In fact, this question seems to be somehow dependent on the base algorithm considered as well as on the dataset of application.

These results lead us to conclude that the proposed approach provides a suitable solution to confront three-class classification problems and improve the decision rule that manages how the intermediate soft information gathered by many classifiers is exploited.

However, we must improve the results in statistical terms so that we could ensure the superiority of our proposed methodology when applied in three-class classification problems by enlarging the benchmark of datasets, and considering several different parametric configuration for training the base classifier as well as the evolutionary search of the dissimilarity structure among the set of classes.

Regarding future research on this approach, a main line of work will be devoted to study further mechanisms than the additive and logistic aggregations for exploiting the bipolar

pairs of positive and negative evidence. A particularly appealing possibility is to use these bipolar pairs as the base information of a multivalued para-consistent logic, as those proposed in [9], [10], [12]. This would allow an even more expressive representational framework to take advantage of all the information contained in the soft scores provided by classifiers.

#### ACKNOWLEDGEMENT

This research has been partially supported by the Government of Spain, grant TIN2015-66471-P and the FPU fellowship grant 2015/06202 from the Ministry of Education of Spain.

#### REFERENCES

- [1] J. Alcalá-Fdez, A. Fernández, J. Luengo, J. Derrac, S. García, L. Sánchez, and F. Herrera, (2011) KEEL data-mining software tool: Data set repository, integration of algorithms and experimental analysis framework. *Journal of Multiple-Valued Logic and Soft Computing*, vol. 17:2-3, pp. 255-287.
- [2] Breiman L. (1984) Classification and Regression Trees. New York, NY: Kluwer Academic Publishers;
- [3] Breiman L. (2001) Random Forests. *Mach. Learn.* vol.40 5-32.
- [4] Demsar J., (2006) Statistical comparisons of classifiers over multiple datasets, *J. Mach. Learn. Res.* 7 1-30.
- [5] García S., Fernández A., Luengo J. and Herrera F., (2010) Advanced nonparametric tests for multiple comparisons in the design of experiments in computational intelligence and data mining: Experimental analysis of power, *Inform. Sciences* 180(10) 2044-2064.
- [6] Holm S., (1979) A simple sequentially rejective multiple test procedure, *Scand. J. Stat.* 6 65-70.
- [7] Kumar, R. and Verma, R. (2012) Classification algorithms for data mining: A survey, *International Journal of Innovations in Engineering and Technology*, 2 7-14.
- [8] Lim, TS., Loh, WY. and Shih, YS. (2000) A Comparison of Prediction Accuracy, Complexity, and Training Time of Thirty-Three Old and New Classification Algorithms, *Machine Learning*, 40 203-228.
- [9] Ozturk, M., Tsoukiàs, A. (2007) Modeling uncertain positive and negative reasons in decision aiding. *Decis. Support Syst.* 43, 1512-1526
- [10] Turunen, E., Ozturk, M., Tsoukiàs, A. (2010) Paraconsistent semantics for Pavelka style fuzzy sentential logic. *Fuzzy Sets Syst.* 161, 1926-1940
- [11] Ripley, B. D. (1996) *Pattern Recognition and Neural Networks*. Cambridge.
- [12] Rodríguez, J.T., Turunen, E., Ruan, D., Montero, J. (2014) Another paraconsistent algebraic semantics for Lukasiewicz-Pavelka logic. *Fuzzy Sets Syst.* 242, 132-147
- [13] Rodríguez, J. T., Vitoriano, B., Montero, J. (2011) Rule-based classification by means of bipolar criteria. 2011 IEEE Symposium on Computational Intelligence in Multicriteria Decision-Making (MDCM), 197-204.
- [14] Rodríguez, J. T., Vitoriano, B., Montero, J. (2012) A general methodology for data-based rule building and its application to natural disaster management. *Computers & Operations Research*, 39 (4) 863-873.
- [15] Rodríguez JT, Vitoriano B, Gómez D, Montero, J. (2013) Classification of Disasters and Emergencies under Bipolar Knowledge Representation. In: Vitoriano B, Montero J and Ruan D (eds), *Decision Aid Models for Disaster Management and Emergencies*, vol. 7, Atlantis Computational Intelligence Systems, 209-232.
- [16] Venables, W. N. and Ripley, B. D. (2002) *Modern Applied Statistics with S*. Fourth edition. Springer.
- [17] Villarino, G., Gómez, D., Rodríguez, J. T. (2017). Improving Supervised Classification Algorithms by a Bipolar Knowledge Representation. In *Advances in Fuzzy Logic and Technology 2017* (pp. 518-529).
- [18] Villarino, G., Gómez, D., Rodríguez, J.T. et al. *Soft Comput* (2018). <https://doi.org/10.1007/s00500-018-3320-9>
- [19] Wilcoxon F., (1945) Individual comparisons by ranking methods, *Biometrics* 1 80-83.
- [20] Willighagen E., (2005) *genalg: R Based Genetic Algorithm*. <http://cran.r-project.org/>
- [21] Kuhn M., (2008) Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5) 1-26. [doi:http://dx.doi.org/10.18637/jss.v028.i05](http://dx.doi.org/10.18637/jss.v028.i05)

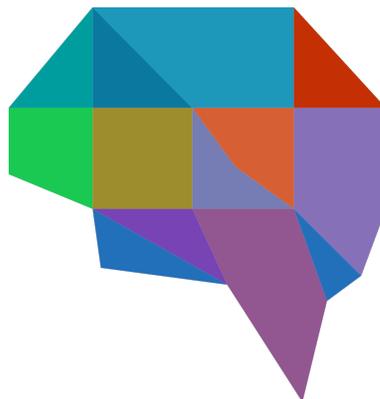


**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 6: SESIÓN ESPECIAL:  
NUEVOS ENFOQUES Y  
APLICACIONES EN LA TOMA  
DE DECISIONES EN AMBIENTES  
DE INCERTIDUMBRE I

**Organizadores:**

ROCÍO DE ANDRÉS, TERESA GONZÁLEZ ARTEAGA







# A universal decision making model for restructuring networks based on Markov Random Fields\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Julia García Cabello

*Department of Applied Mathematics*  
*University of Granada*  
Granada, Spain  
cabello@ugr.es

Enrique Herrera-Viedma

*Department of Computer Science and Artificial Intelligence*  
*University of Granada*  
Granada, Spain  
viedma@decsai.ugr.es

**Abstract**—The process of re-structuring physical networks is often based on local demographics. However, there are major variations across countries when defining demographics according to “local” parameters, which hinders the export of methodologies based on local specifications. This paper presents a *universal* decision making model for re-structuring networks aimed at working on a global basis since local parameters has been replaced by “internationally accepted” notions thereby allowing cross-border correlations. This a first step towards the globalization of demographic parameters which would also be fruitful in other disciplines where demographics play a role.

Importantly, the model variables can be replaced/expanded as needed thereby providing a decision making tool that can be applied to a wide range of contexts.

**Index Terms**—Universal Decision Model, Spatial stochastic processes (Markov and Gibbs Random Fields)

# Un modelo de consenso para toma de decisiones en grupo a gran escala usando conjuntos difusos dudosos

1<sup>st</sup> Rosa M. Rodríguez  
*Dept. de Ciencias de la Computación e I.A.*  
*Universidad de Granada*  
Granada, España  
rosam.rodriguez@decsai.ugr.es

2<sup>th</sup> Álvaro Labella  
*Dept. de Informática*  
*Universidad de Jaén*  
Jaén, España  
alabella@ujaen.es

3<sup>rd</sup> Luis Martínez  
*Dept. de Informática*  
*Universidad de Jaén*  
Jaén, España  
martin@ujaen.es

**Resumen**—El desarrollo tecnológico y las demandas de la sociedad han provocado que los problemas de toma de decisiones en grupo a gran escala (TDG-GS) sean cada vez más comunes. Muchos de estos problemas requieren soluciones aceptadas por todos los expertos involucrados. Para ello, se aplica un proceso de alcance de consenso. Algunos retos de los procesos de alcance de consenso para problemas de TDG-GS son, la escalabilidad y el proceso de supervisión de las preferencias de los expertos, lo que afecta al coste temporal. Teniendo en cuenta estos retos, esta contribución presenta un nuevo modelo de consenso para problemas de TDG-GS capaz de reducir el coste temporal del proceso de alcance de consenso.

**Index Terms**—toma de decisiones en grupo a gran escala, proceso de alcance de consenso, clustering, conjunto difuso dudoso

## I. INTRODUCCIÓN

Hoy en día existen muchos problemas que afectan a la sociedad y requieren decisiones consensuadas. En estos casos, es necesario aplicar un proceso de alcance de consenso (PAC) [8]. La mayoría de los resultados que se han obtenido en este área se centran en toma de decisiones en grupo (TDG) con pocos expertos, sin embargo el desarrollo tecnológico y la actual demanda de la sociedad (redes sociales, e-group shopping) hacen necesario proponer PAC que sean capaces de manejar problemas con grandes grupos (como se indicó en [2] más de 20 expertos). Esta situación implica la aparición de nuevos retos en los PAC, como ya ha sido mencionado por otros investigadores [3]: i) escalabilidad, ii) coste temporal, iii) supervisión constante de las preferencias, iv) fuerte desacuerdo entre expertos, v) dificultades para entender/visualizar el actual estado de acuerdo entre expertos, etc.

El estudio de TDG a gran escala (TDG-GS), se puede clasificar en 4 temáticas:

- Métodos de clustering en TDG-GS
- PAC en TDG-GS
- Modelos de TDG-GS
- Sistemas de soporte para TDG-GS

Recientemente se han indicado las principales limitaciones que los PAC clásicos presentan cuando éstos son aplicados

a problemas de TDG-GS [3], [4] y aunque existen ya algunas propuestas iniciales, aún no son capaces de evitar estas limitaciones.

Por tanto, teniendo en cuenta los retos, y las limitaciones de los PAC clásicos en los problemas de TDG-GS, esta contribución presenta un modelo de consenso para TDG-GS que evita el problema de la escalabilidad y la constante supervisión de las preferencias, ambos relacionados con el coste temporal del PAC. Esta propuesta incluye las siguientes novedades:

- Detecta subgrupos de expertos teniendo en cuenta la similitud de sus preferencias y calcula la relevancia de cada subgrupo considerando su tamaño y cohesión.
- La mayoría de los PAC agregan las preferencias de los expertos al principio del proceso, esto provoca pérdida de información y por tanto desviación en los resultados. Para evitar esta situación, esta propuesta modela las preferencias de los subgrupos de expertos mediante conjuntos difusos dudosos (CDD) [9].
- Define un nuevo proceso de feedback adaptativo que guía el PAC según el grado de consenso alcanzado en cada momento.

El resto de esta contribución se organiza como sigue: la Sección 2 hace una breve revisión sobre TDG-GS y CDD. La Sección 3 presenta un nuevo modelo de consenso para resolver problemas de TDG-GS que utiliza CDD, y finalmente, la Sección 4 termina con algunas conclusiones.

## II. PRELIMINARES

Esta sección revisa algunos conceptos básicos sobre TDG-GS, PAC y CDD que serán utilizados en el modelo de consenso propuesto.

### II-A. Toma de decisiones en grupo a gran escala

El concepto de TDG-GS es muy similar al de TDG, con la diferencia de que en el primero el número de expertos que participa en el problema es mucho más grande que en el segundo. Un problema de TDG-GS consiste de i) un conjunto de alternativas  $X = \{x_1, \dots, x_n\}$ , ( $n \geq 2$ ) como



posible solución al problema, y un conjunto de expertos  $E = \{e_1, \dots, e_m\}$ , ( $m \gg n$ ), que expresan sus opiniones sobre el conjunto de alternativas  $X$ . Una estructura muy utilizada por los expertos para proporcionar sus preferencias en ambos tipos de problemas de TDG es la relación de preferencia difusa,  $P = (p_{ij})_{n \times n} \subset X \times X$ ,  $p_{ij} \in [0, 1]$ .

Los problemas de TDG-GS se pueden resolver mediante un proceso de selección, similar al utilizado en TDG. Sin embargo, este proceso no garantiza que la decisión seleccionada sea siempre aceptada por todos los expertos que participan en el problema, ya que algunos de ellos podrían considerar que sus opiniones no se tuvieron en cuenta. Una posible solución para evitar este inconveniente y obtener decisiones aceptadas por todos los expertos involucrados en el problema, es añadir un PAC. Este proceso implica que los expertos modifiquen sus preferencias para que estén más cerca de la opinión colectiva.

Un proceso de alcance de consenso es un proceso de discusión iterativo y dinámico que puede realizarse de diferentes formas, tal y como se indica en [4]. La Figura 1 muestra un esquema general de un PAC.

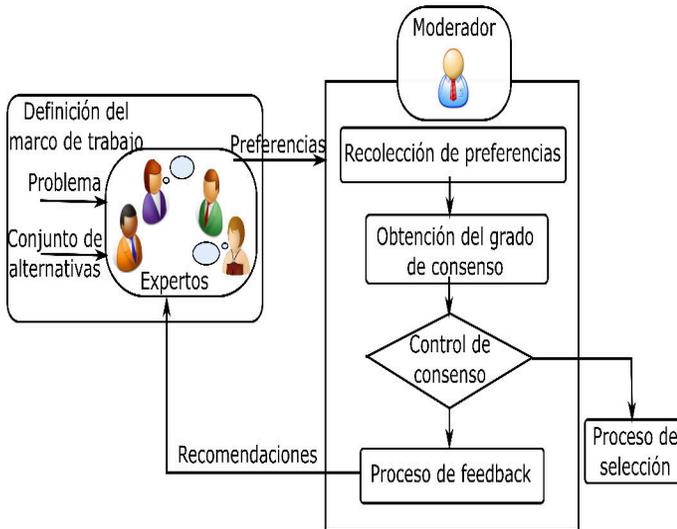


Figura 1. Esquema general de un PAC

En TDG-GS también es necesario aplicar un PAC para obtener soluciones aceptadas por todos los expertos involucrados. Varias propuestas han sido ya introducidas en [5], [6], [10], sin embargo, estas propuestas agregan las preferencias de los expertos al inicio del proceso de decisión, lo que implica pérdida de información y no tienen en cuenta el nivel de acuerdo alcanzado a lo largo del PAC, lo que puede provocar un alto coste temporal, ya que requiere una mayor supervisión de las preferencias durante el proceso de discusión y feedback.

Para evitar estas limitaciones, nuestro modelo incluye un proceso para detectar y ponderar subgrupos, mantener la información inicial fusionando las preferencias mediante CDD en lugar de usar técnicas de agregación, y definir un nuevo proceso de feedback adaptativo.

## II-B. Uso de información dudosa

El concepto de CDD introducido en [9], modela la incertidumbre obtenida de la duda que puede tener un experto cuando quiere asignar el grado de pertenencia de un elemento a un conjunto.

**Definición 1:** [9] Sea  $X$  un conjunto de referencia, un conjunto difuso dudoso sobre  $X$  es una función  $h$  que devuelve un subconjunto de valores en el intervalo  $[0, 1]$ :

$$h : X \rightarrow \wp([0, 1]). \quad (1)$$

Esta definición fue completada con la siguiente representación matemática,  $A = \{\langle x, h_A(x) \rangle : x \in X\}$ , donde  $h_A(x)$  es un elemento difuso dudoso (EDD) y es un conjunto de valores en  $[0, 1]$ .

También se definió el concepto de relación de preferencia difusa dudosa para problemas de TDG.

**Definición 2:** [11] Sea  $X$  un conjunto de referencia, una relación de preferencia difusa dudosa (RPDD) sobre  $X$  se representa mediante la matriz  $H = (h_{ij})_{n \times n} \subset X \times X$ , donde  $h_{ij} = \{\gamma_{ij}^s | s = 1, 2, \dots, \#h_{ij}\}$  ( $\#h_{ij}$  es el número de elementos en  $h_{ij}$ ) es un EDD que indica el grado de pertenencia para el cual  $x_i$  es preferido a  $x_j$ . Además,

$$\gamma_{ij}^{\sigma(s)} + \gamma_{ji}^{\sigma'(s)} = 1, \quad h_{ii} = \{0, 5\}, \quad \#h_{ij} = \#h_{ji}, \quad i, j = \{1, 2, \dots, n\}$$

donde  $\{\sigma(1), \dots, \sigma(\#h_{ij})\}$  es una permutación de  $\{1, \dots, \#h_{ij}\}$ , tal que,  $\gamma_{ij}^{\sigma(s)}$  es el  $s^{\text{th}}$  elemento más pequeño en  $h_{ij}$ .

En algunas ocasiones para realizar operaciones con CDD es necesario que el número de elementos contenidos en el EDD sea el mismo para poder realizar los cálculos de forma adecuada. Para ello es necesario aplicar un proceso de normalización.

**Definición 3:** Sea  $h_i$  el EDD con menor cardinalidad y  $h_i^- = \min\{\gamma | \gamma \in h_i\}$  y  $h_i^+ = \max\{\gamma | \gamma \in h_i\}$ , entonces el valor  $\gamma'$  que se añade en el EDD,  $h_i$ , es calculado como sigue:

$$\gamma' = \eta h_i^+ + (1 - \eta) h_i^-, \quad (2)$$

donde  $\eta (0 \leq \eta \leq 1)$ , es un parámetro de optimización que refleja la actitud que tiene el experto respecto al riesgo. Si  $\eta = 1$ , el valor añadido es  $\gamma' = h_i^+$ , que indica un punto de vista optimista; si  $\eta = 0$ , el valor añadido es  $\gamma' = h_i^-$ , que indica un punto de vista pesimista; y si  $\eta = 1/2$ , entonces  $\gamma' = 1/2(h_i^+ + h_i^-)$ , lo que significa que el experto es neutro.

## III. MODELO DE CONSENSO ADAPTATIVO PARA TDG-GS

Esta sección presenta un nuevo modelo de consenso para TDG-GS capaz de tratar con el problema de escalabilidad y la constante supervisión de las preferencias de los expertos en el proceso de feedback.

- Para lograr el primer objetivo, el modelo incluye un proceso de clustering para detectar subgrupos de expertos basado en la similitud de sus preferencias. Las preferencias de cada subgrupo son modeladas mediante CDD que

representan la duda del grupo. Además los subgrupos son ponderados según su tamaño y cohesión.

- El segundo objetivo es alcanzado mediante un proceso adaptativo que modifica el proceso de feedback en el PAC atendiendo al grado de consenso alcanzado en cada ronda.

El modelo extiende el esquema general mostrado en la Figura 1 añadiendo dos nuevas fases: i) gestión de subgrupos, ii) proceso de feedback adaptativo, y modifica otras dos: i) definición del marco de trabajo, ii) obtención del grado de consenso. El modelo se divide por tanto en 6 fases (ver Fig. 2).

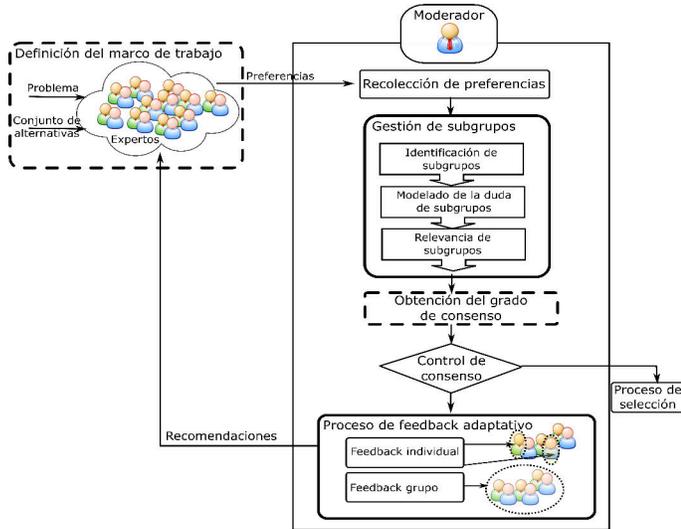


Figura 2. Esquema del modelo de consenso propuesto

### III-A. Definición del marco de trabajo

En un problema de TDG-GS hay un conjunto de posibles alternativas  $X = \{x_1, \dots, x_n\}$  y un gran número de expertos  $E = \{e_1, \dots, e_m\}$  implicados en el problema, siendo  $m \gg n$ . Normalmente se definen dos parámetros, el umbral de consenso y el número máximo de rondas de discusión. Sin embargo, en este modelo es necesario introducir un nuevo parámetro que pueda controlar el proceso adaptativo a lo largo del PAC. Por tanto, en nuestro modelo se definen 3 parámetros:

- $\vartheta \in [0, 1]$ : es el umbral de consenso establecido para alcanzar el consenso.
- $\delta \in [0, 1]$ ,  $\delta < \vartheta$ : es un parámetro que se utiliza en el proceso de feedback adaptativo para determinar el nivel de consenso alcanzado (alto o bajo).
- $Max\_rondas$ : este parámetro controla el número máximo de rondas permitidas en el problema de TDG-GS.

### III-B. Recolección de preferencias

Cada experto  $e_r \in E$ , proporciona sus preferencias sobre  $X$  mediante una relación de preferencia difusa (RPD),  $P^r = (p_{ij}^r)_{n \times n}$ , la cual es recíproca  $p_{ij}^r + p_{ji}^r = 1$ ,  $i, j \in 1, \dots, n$ .

### III-C. Gestión de subgrupos

Como hemos comentado anteriormente, el primer objetivo que nos planteamos alcanzar es evitar el problema de escalabilidad en TDG-GS y para ello consideramos que de todos los expertos involucrados en el problema, algunos de ellos tienen preferencias similares. Por tanto, la idea principal en esta fase es reducir el número de preferencias. Esta fase se divide en 3 procesos.

#### 1) Identificación de subgrupos

Para identificar grupos de expertos con preferencias similares aplicamos un algoritmo basado en el fuzzy c-means, pero adaptado a nuestro problema.

- Inicialmente hay un cluster para cada alternativa,  $C = \{C^1, \dots, C^n\}$ .
- Se obtiene un centroide  $c^l$  para cada cluster. Existen distintas formas de inicializar los centroides, en esta propuesta como el problema es conocido, cada centroide es inicializado con una RPD que representa la preferencia de una alternativa sobre el resto:
 
$$c^l = \begin{pmatrix} - & 1 & 1 & \dots & 1 \\ 0 & - & 0,5 & \dots & 0,5 \\ 0 & 0,5 & - & \dots & 0,5 \\ \vdots & \dots & \dots & \dots & \vdots \\ 0 & 0,5 & 0,5 & \dots & - \end{pmatrix}, \dots, c^n = \begin{pmatrix} - & 0,5 & 0,5 & \dots & 0 \\ 0,5 & - & 0,5 & \dots & 0 \\ 0,5 & 0,5 & - & \dots & 0 \\ \vdots & \dots & \dots & \dots & \vdots \\ 1 & 1 & 1 & \dots & - \end{pmatrix}$$
- Se calcula el grado de pertenencia de cada RPD,  $P^r$ , a cada centroide  $c^{l,t}$ ,  $\mu_{c^{l,t}}(P^r) \in [0, 1]$ ,

$$\mu_{c^{l,t}}(P^r) = \frac{(1/d(P^r, c^{l,t}))^{1/(b-1)}}{\sum_{u=1}^n (1/d(P^r, c^{u,t}))^{1/(b-1)}} \quad (3)$$

donde  $d(P^r, c^{l,t})$  es la distancia de Minkowski,  $t$  es la iteración actual, y  $b$  indica el grado de difusidad de los clusters. Cuanto mayor sea el valor de  $b$ , más difuso es el cluster [1]. Normalmente este parámetro se fija con el valor 2.

- Se calculan los nuevos centroides según las RPD de los expertos incluidas en cada cluster.

$$c_{ij}^{l,t+1} = \frac{1}{|C^{l,t}|} \sum_{P^r \in C^{l,t}} p_{ij}^r, i, j \in \{1, \dots, n\}, \quad (4)$$

donde  $|C^{l,t}|$  es el número de relaciones de preferencia que pertenecen al cluster  $C^l$  en la iteración  $t$ .

- El algoritmo termina cuando todos los clusters se estabilizan, es decir, cuando la variación de los grados de preferencia entre dos iteraciones consecutivas se acercan a 0.

$$\frac{\sum_{r=1}^m \sum_{l=1}^n |\mu_{c^{l,t}}(P^r) - \mu_{c^{l,t-1}}(P^r)|}{m \cdot n} \leq \epsilon \quad (5)$$

donde  $\epsilon$  es un umbral que debería ser cercano a 0.

#### 2) Modelado de la duda de subgrupos

Para evitar la pérdida de información en las etapas iniciales del PAC, en lugar de simplificar el modelado de preferencias aplicando técnicas de agregación, en esta propuesta consideramos que aunque las preferencias de los expertos en el subgrupo sean similares, reflejan la duda del grupo. Por tanto,



sea  $G^l = \{e_1^l, \dots, e_n^l\}$  un subgrupo de expertos que pertenece al cluster,  $C^l$ , con RPD,  $P^{l1} = (p_{ij}^{l1})_{n \times n}, \dots, P^{lr} = (p_{ij}^{lr})_{n \times n}$ , construimos una RPDD,  $HP^l = (h_{ij}^l)_{n \times n}$ ,  $l \in \{1, \dots, n\}$ , fusionando las preferencias de todos los expertos del subgrupo  $G^l$ , tal que,  $h_{ij}^l = \{p_{ij}^{lk} | k = 1, 2, \dots, |G^l|\}$  siendo  $|G^l|$  la cardinalidad de  $G^l$ .

### 3) Relevancia de subgrupos

La relevancia de cada subgrupo se obtiene mediante dos características:

- Tamaño: es el número de expertos del subgrupo.
- Cohesión: indica cómo de cerca están los expertos unos de otros dentro del grupo.

El tamaño se puede obtener directamente del proceso de *identificación de subgrupos*, sin embargo, para obtener la cohesión es necesario definir un nuevo enfoque. Esta fase se divide en 3 pasos que se detallan a continuación.

#### a) Cálculo de la cohesión de un subgrupo

Para obtener la cohesión de las preferencias de los expertos  $HP^l = (h_{ij}^l)_{n \times n}$ , que pertenecen al subgrupo  $G^l$ , hemos definido un método geométrico que consiste en calcular el área dada por las valoraciones máximas y mínimas de  $h_{ij}^l$ , sobre el conjunto de alternativas  $X$ . Como se puede observar en la Figura 3, el eje de abscisas  $X$  representa el conjunto  $Z$  formado por todos los pares de alternativas, donde cada par  $z_t = (x_i, x_j), j \in \{1, 2, 3\}, i \neq j$  es colocado equidistantemente sobre el eje de abscisas  $X$ . El área se obtiene mediante los valores máximo,  $p_{ij}^+$ , y mínimo,  $p_{ij}^-$ , de cada par de alternativas. Para ello es necesario establecer el orden en el que los pares de alternativas son colocados en el eje de abscisas  $X$ . En esta propuesta, hemos considerado las valoraciones mínimas en orden creciente.

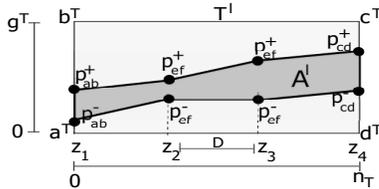


Figura 3. Representación gráfica de la cohesión de un subgrupo.

Formalmente el método geométrico se define como sigue:

1. Sea  $T^l$  el área total del rectángulo definido por los puntos  $a^T, b^T, c^T$  y  $d^T$  (ver Fig. 3), i.e.,  $T^l = g^T \times n^T$ .
2. Sea  $I = \bigcup_{i,j \in n, i \neq j} \{(i, j)\}$  un conjunto con todas las posibles combinaciones sobre el conjunto de alternativas  $X = \{x_1, \dots, x_n\}$ . Los valores máximos y mínimos para cada par de alternativas se obtienen de la siguiente forma:

$$\gamma_{ij}^- = \min\{\gamma_{ij}^1, \gamma_{ij}^2, \dots, \gamma_{ij}^s\}, \forall (i, j) \in I$$

$$\gamma_{ij}^+ = \max\{\gamma_{ij}^1, \gamma_{ij}^2, \dots, \gamma_{ij}^s\}, \forall (i, j) \in I$$

El primer y último par de alternativas considerado en el eje de la  $X$  son:

$$\gamma_{ab}^- = \min_{i,j \in I} \{\gamma_{ij}^-\}, (a, b) \in I$$

$$\gamma_{cd}^+ = \max_{i,j \in I} \{\gamma_{ij}^+\}, (c, d) \in I$$

Definimos una función  $f$  para obtener los índices de los pares de alternativas,  $f : \{z_1, z_2, \dots, z_{n(n-1)}\} \rightarrow I$ .

El área  $A^l$ , comprendida entre los valores máximo y mínimo ordenados en el eje de la  $X$  se calcula como sigue:

$$A^l = \left[ \sum_{i,j \in I} (\gamma_{ij}^+ - \gamma_{ij}^-) - \frac{(\gamma_{ab}^+ - \gamma_{ab}^-) + (\gamma_{cd}^+ - \gamma_{cd}^-)}{2} \right] \cdot D \quad (6)$$

donde  $D$  es la distancia entre  $z_i$  y  $z_{i+1}$ , que en este caso es 1.

3. Finalmente se obtiene la cohesión,

$$cohesion(G^l) = 1 - \frac{A^l}{T^l} \quad (7)$$

#### b) Cálculo del tamaño de un subgrupo

El valor del tamaño de un subgrupo  $G^l$ , se puede obtener directamente de la fase de *identificación de subgrupos*, pero su representación debe ser ajustada y adaptada al número de expertos que participan en el problema de TDG-GS. Para ello, proponemos un proceso basado en computación con palabras en el que el tamaño es modelado mediante una función de pertenencia difusa  $\mu_{tamaño}$  como la mostrada en la Figura 4, en la que el universo de discurso es el número de expertos en el subgrupo. Los puntos  $a$  y  $b$  de la función dependen del número de alternativas y expertos en el problema de TDG-GS.

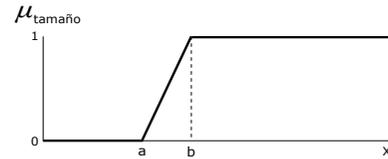


Figura 4. Función de pertenencia

#### c) Cálculo de la relevancia de un subgrupo

Para obtener el peso de cada subgrupo, agregamos los valores que hemos obtenido para el tamaño y cohesión con la siguiente función.

*Definición 4:* Sea  $Y_{G^l} = \{y_1, y_2\}$  los valores obtenidos para el tamaño y cohesión,  $y_1, y_2 \in [0, 1]$ , del subgrupo  $G^l$ , los cuales son agregados mediante la siguiente ecuación,

$$\varphi(Y_{G^l}) = (1 + y_2)^{y_1 \beta} \quad (8)$$

siendo  $\beta > 0$  un parámetro para incrementar/decrementar la influencia de la cohesión en el cálculo del peso.

Finalmente, estos valores son normalizados.

$$w_l = \frac{\varphi(Y_{G^l})}{\sum_{z=1}^n \varphi(Y_{G^z})}, \forall l \in \{1, \dots, n\}. \quad (9)$$

#### III-D. Obtención del grado de consenso

El grado de consenso entre expertos se calcula mediante un proceso de 3 pasos.

1. Para cada par de subgrupos  $G^l$  y  $G^k$ , se calcula una matriz de similitud  $MS^{lk} = (m_{ij}^{lk})_{n \times n}$ ,  $m_{ij}^{lk} = 1 -$

$d(h_{ij}^l, h_{ij}^k)$ , donde  $d$  es una medida de distancia para EDD [7].

En este paso hay que tener en cuenta que si el número de valores en el EDD de cada RPDD es diferente, es necesario aplicar un proceso de normalización (ver Def. 3. Por tanto, todas las RPDD  $HP^l(h_{ij}^l)_{n \times n}$ , son normalizadas,  $\overline{HP}^l = (\overline{h}_{ij}^l)_{n \times n}$  antes de calcular las matrices de similitud.

2. Las matrices de similitud son agregadas para obtener una matriz de consenso,  $MC = (mc_{ij})_{n \times n}$ . Aunque diferentes operadores de agregación pueden ser utilizados, sin pérdida de generalidad en esta propuesta usamos la media aritmética,

$$mc_{ij} = \frac{\sum_{l=1}^{n-1} \sum_{k=l+1}^n ms_{ij}^{lk}}{n(n-1)/2} \quad (10)$$

3. El grado de consenso se calcula a dos niveles utilizando la matriz de consenso  $MC$ :

- Nivel de alternativas: el grado de consenso para cada alternativa se calcula como,

$$ca_i = \frac{1}{n-1} \sum_{j=1, i \neq j}^n mc_{ij} \quad (11)$$

- Nivel de relación de preferencia: el grado de consenso entre todos los expertos que participan en el problema de TDG-GS se calcula como,

$$gc = \frac{1}{n} \sum_{i=1}^n ca_i \quad (12)$$

### III-E. Control de consenso

En esta fase se compara el grado de consenso  $gc$  obtenido en la fase anterior, con el umbral de consenso establecido  $\vartheta \in [0, 1]$ . Si  $gc \geq \vartheta$ , el proceso de consenso termina, en caso contrario, es necesario realizar otra ronda de discusión. El número máximo de rondas viene dado por el parámetro  $Max\_rondas$ .

### III-F. Proceso de feedback adaptativo

Cuando el grado de consenso alcanzado  $gc$  no es suficiente, es necesario realizar otra ronda de discusión para incrementar el grado de consenso entre los expertos que participan en el problema. Esta ronda de discusión está guiada por un proceso de feedback. Los modelos de consenso existentes para TDG-GS no tienen en cuenta el grado de consenso alcanzado en cada ronda para adaptar el proceso de feedback, esto implica un proceso de supervisión más complejo y largo. Dado que el segundo objetivo de esta propuesta es reducir la constante supervisión de las preferencias de los expertos, en este modelo se define un proceso de feedback adaptativo que adapta la generación de recomendaciones según el grado de consenso alcanzado en cada ronda. Para distinguir entre los dos procesos de feedback, se introduce un nuevo parámetro  $\delta$ . El proceso de feedback se divide en 3 pasos.

- Obtener una matriz colectiva,  $HP^C$ , agregando las preferencias representadas mediante RPDD normalizadas

$\{\overline{HP}^1, \dots, \overline{HP}^n\}$  utilizando un operador de agregación para CDD [7].

- Calcular la proximidad entre cada subgrupo  $\{\overline{HP}^1, \dots, \overline{HP}^n\}$ , y la matriz colectiva  $HP^C$ , utilizando una medida de similitud para CDD [7]:

$$pr^l = sim(HP^C, \overline{HP}^l) = 1 - d(HP^C, \overline{HP}^l) \quad (13)$$

Los valores de proximidad obtenidos  $pr$ , son utilizados para identificar a los subgrupos más alejados de la opinión colectiva.

- Dependiendo del nivel de consenso alcanzado, el proceso de feedback puede ir dirigido a todos los expertos de un subgrupo o sólo a aquellos expertos más alejados. A continuación definimos ambos procesos.

#### Proceso de feedback en grupo

Cuando el grado de consenso  $gc < \delta$ , significa que el consenso es *bajo* y es necesario realizar muchos cambios para incrementar el grado de consenso. En este caso, se recomienda a todos los expertos de los subgrupos más alejados que modifiquen sus preferencias. Para ello, es necesario identificar los subgrupos más alejados y seleccionar los pares de alternativas a cambiar.

- Si  $pr^l \leq \overline{pr}$ , entonces seleccionamos el subgrupo  $G^l$ , donde  $\overline{pr}$  es el valor medio de los valores de proximidad obtenidos,  $\overline{pr} = \frac{1}{n} \sum_{l=1}^n pr^l$ .
- Si  $ca_i \leq \vartheta$ , entonces seleccionamos la alternativa  $x_i$  y buscamos los pares de alternativas,
  - Si  $pr_{ij}^l \leq \overline{pr}_i$ , entonces seleccionamos el par de alternativas  $(x_i, x_j)$ , siendo  $\overline{pr}_i = \frac{1}{n} \sum_{j=1}^n pr_{ij}^l$  y  $pr_{ij}^l = 1 - d(h_{ij}^C, h_{ij}^l)$ .

Una vez se hayan identificado los subgrupos y pares de alternativas, es necesario establecer la dirección del cambio, es decir, si hay que incrementar o decrementar los valores de las preferencias. Las reglas de dirección son las siguientes:

- Si  $\nu(h_{ij}^l) < \nu(h_{ij}^C)$ , entonces todos los expertos que pertenecen al subgrupo  $G^l$  deberían incrementar sus preferencias para el par de alternativas  $(x_i, x_j)$ .
- Si  $\nu(h_{ij}^l) > \nu(h_{ij}^C)$ , entonces todos los expertos que pertenecen al subgrupo  $G^l$  deberían decrementar sus preferencias para el par de alternativas  $(x_i, x_j)$ .

Donde los valores  $\nu(h_{ij}^l)$  y  $\nu(h_{ij}^C)$  son obtenidos mediante la función de score para EDD definida mediante la siguiente ecuación:

$$\nu(h) = \frac{1}{\#h} \sum_{s=1}^{\#h} \gamma^s \quad (14)$$

#### Proceso de feedback individual

En este caso  $\delta \leq gc < \vartheta$ , lo que significa que el nivel de consenso es *alto*, pero no lo suficiente para alcanzar el consenso, por tanto, el número de cambios es mucho menor que con el anterior proceso de feedback, y sólo aquellos expertos cuya opinión esté más alejada de la opinión colectiva tienen que cambiar sus preferencias. Para ello, hay que identificar el



subgrupo  $G^l$ , el par de alternativas  $(x_i, x_j)$  y los expertos  $e_r$  que están en desacuerdo.

- Si  $pr^l \leq \overline{pr}$ , entonces seleccionamos el subgrupo  $G^l$ .
- Si  $ca_i \leq \vartheta$ , entonces seleccionamos la alternativa  $x_i$  y
  - Si  $pr_{ij}^l \leq \overline{pr}_i$ , entonces seleccionamos el par de alternativas  $(x_i, x_j)$ .
- Si  $1 - d(\nu(h_{ij}^C), p_{ij}^{lr}) \leq \overline{pr}_i$ , entonces seleccionamos el experto  $e_r$ .

Los expertos seleccionados deberían cambiar sus preferencias según las siguientes reglas de dirección.

- Si  $p_{ij}^{lr} < \nu(h_{ij}^C)$ , entonces el experto  $e_r \in G^l$  debería incrementar su preferencia sobre el par de alternativas  $(x_i, x_j)$ .
- Si  $p_{ij}^{lr} > \nu(h_{ij}^C)$ , entonces el experto  $e_r \in G^l$  debería decrementar su preferencia para el par de alternativas  $(x_i, x_j)$ .
- Si  $p_{ij}^{lr} = \nu(h_{ij}^C)$ , no es necesario realizar cambios.

#### IV. CONCLUSIONES

Los problemas de TDG-GS son cada vez más comunes y las decisiones son más apreciadas y aceptadas por los expertos involucrados cuando éstas son consensuadas. Para ello, es necesario aplicar PAC. Los modelos de consenso existentes, consumen mucho tiempo, debido a la supervisión de las preferencias de los expertos y en problemas de TDG-GS este tiempo se incrementa. Por tanto, esta contribución se centra en reducir el coste temporal relacionado con la escalabilidad y el proceso de supervisión de las preferencias de los expertos definiendo un nuevo modelo de consenso para TDG-GS.

#### AGRADECIMIENTOS

Este trabajo está parcialmente financiado por el proyecto de investigación TIN2015-66524-P, el Ministerio de Economía y Competitividad Juan de la Cierva Incorporación (FPDI-2013-18193) y fondos FEDER.

#### REFERENCIAS

- [1] J. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Springer, 1981.
- [2] X.H. Chen and Rong Liu. Improved clustering algorithm and its application in complex huge group decision-making. *Systems Engineering and Electronics*, 28(11):1695–1699, 2006.
- [3] Á. Labella, Y. Liu, R. M. Rodríguez, and L. Martínez. Analyzing the performance of classical consensus models in large scale group decision making: A comparative study. *Applied Soft Computing*, 67:677–690, 2018.
- [4] I. Palomares, F.J. Estrella, L. Martínez, and F. Herrera. Consensus under a fuzzy context: Taxonomy, analysis framework afryca and experimental case of study. *Information Fusion*, 20:252–271, 2014.
- [5] I. Palomares, L. Martínez, and F. Herrera. A consensus model to detect and manage noncooperative behaviors in large-scale group decision making. *IEEE Transactions on Fuzzy Systems*, 22(3):516–530, 2014.
- [6] F.J. Quesada, I. Palomares, and L. Martínez. Managing experts behavior in large-scale consensus reaching processes with uninorm aggregation operators. *Applied Soft Computing*, 35:873 – 887, 2015.
- [7] R.M. Rodríguez, L. Martínez, V. Torra, Z.S. Xu, and F. Herrera. Hesitant fuzzy sets: state of the art and future directions. *International Journal of Intelligent Systems*, 29(6):495–524, 2014.
- [8] S. Saint and J. R. Lawson. *Rules for Reaching Consensus. A Modern Approach to Decision Making*. Jossey-Bass, 1994.
- [9] V. Torra. Hesitant fuzzy sets. *International Journal of Intelligent Systems*, 25(6):529–539, 2010.

- [10] X.H. Xu, Z.J. Du, and X.H. Chen. Consensus model for multi-criteria large-group emergency decision making considering non-cooperative behaviors and minority opinions. *Decision Support Systems*, 79:150 – 160, 2015.
- [11] B. Zhu and Z.S. Xu. Regression methods for hesitant fuzzy preference relations. *Technological and Economic Development of Economy*, 19:S214–S227, 2013.

# Free Double Hierarchy Hesitant Fuzzy Linguistic Term Sets in Group Decision-Making

1<sup>st</sup> Jordi Montserrat-Adell  
UPC - BarcelonaTech  
ESADE - Ramon Llull University  
Barcelona, Spain  
jordi.montserrat-adell@upc.edu

2<sup>nd</sup> Zeshui Xu  
Sichuan University  
Chengdu, China  
xuzeshui@263.net

3<sup>rd</sup> Xunjie Gou  
Sichuan University  
Chengdu, China  
University of Granada  
Granada, Spain  
gouxunjie@qq.com

4<sup>th</sup> Núria Agell  
ESADE - Ramon Llull University  
Barcelona, Spain  
nuria.agell@esade.edu

**Abstract**—Hesitant fuzzy linguistic term sets have been an active field of research in recent times. Notwithstanding its usefulness to capture the human way of reasoning using linguistic expressions involving different levels of precision, in some situations they do not depict enough details. In this paper, we present a new kind of linguistic term sets, called free double hierarchy linguistic term sets, and their corresponding free double hierarchy hesitant fuzzy linguistic elements, in order to describe the complexity of linguistic expressions used by the decision makers in a more accurate and precise way. Furthermore, an order and a distance between free double hierarchy hesitant fuzzy linguistic elements are introduced to present an approach based on the TOPSIS method to rank alternatives with free double hierarchy hesitant fuzzy linguistic information by taking into consideration the opinions of a group of decision makers.

**Index Terms**—Linguistic modeling, Group decision-making, Free double hierarchy linguistic term sets, Free double hierarchy hesitant fuzzy linguistic term sets, TOPSIS

## I. INTRODUCTION

This work summarizes the contribution presented by Montserrat-Adell et al. of a new methodology for Group Decision-Making (GDM) under linguistic assessments [4]. In this paper, an extension of the Double Hierarchy Hesitant Fuzzy Linguistic Term Sets (DHHFLTSS) is proposed. Different approaches involving linguistic assessments have been presented in the decision-making literature to deal with the uncertainty connate with human preferences [2], [3]. Furthermore, different levels of precision can be used to give more realistic assessments when uncertainty increases [5]. To model this kind of situations, HFLTSS were introduced in [6].

With the aim of allowing the decision makers (DMs) to express themselves in a more natural way while being more precise on their assessments, Gou et al. introduced the DHSFLTSS [1] by adding a second hierarchy to each linguistic term of the first scale. This allows expressions such as *very good* or *slightly bad* to arise.

This new extension, called the Free Double Hierarchy Hesitant Fuzzy Linguistic Term Sets (FDHFLTSS), overcomes the main issues presented by the DHHFLTSS. The introduction of this new structure, allows each DM involved in a GDM situation to choose the second hierarchy LTS that he or she thinks that suits it better, with as many terms as desired. These

terms can be different for each term of the first hierarchy and for each DM.

Furthermore, an order and a distance between FDHFLTEs are also presented in this paper in order to compare and quantify distances between linguistic assessments provided by the decision makers by means of the aforementioned structure. These order and distance are used to introduce a free double hierarchy approach based on the well-known multi-criteria decision-making TOPSIS ranking method, enabling us to rank alternatives that have been assessed by means of free double hierarchy hesitant fuzzy linguistic information.

The rest of this paper is structured as follows: Section II summarizes the main contributions of the original paper and Section III presents the most remarkable conclusions and lines of futures research of the topic.

## II. FREE DOUBLE HIERARCHY

DHLTSS are a useful tool to describe, in a mathematical way, possible linguistic assessments provided by the decision makers in a group decision-making problem. Yet they present some shortcomings such as the fact that the second hierarchy scale is the same for all the linguistic terms of the first hierarchy. However, whilst “*extremely*” applies well for some linguistic terms such as “*good*” (resulting in “*extremely good*”), it does not apply that well for some other linguistic terms, leading to confusing, or even meaningless, linguistic terms such as “*extremely regular*”. Same thing happens with “*almost perfect*”, which is a clear and common linguistic expression, and “*almost regular*”, which is not clear. In order to fix this issue, we propose the following extension of the DHLTSS:

**Definition 1:** Let  $\mathcal{S} = \{s_t \mid t = -\tau, \dots, -1, 0, 1, \dots, \tau\}$  and  $\mathcal{O}^t = \{o_k^t \mid k = -\zeta_t, \dots, -1, 0, 1, \dots, \zeta_t\}$  for all  $t \in \{-\tau, \dots, -1, 0, 1, \dots, \tau\}$  be the first and second hierarchies of LTSs respectively. Then, a *Free Double Hierarchy Linguistic Term Set (FDHFLTSS)*,  $\mathcal{S}_{\mathcal{O}}^{\mathcal{F}}$ , can be expressed in a mathematical form as:

$$\mathcal{S}_{\mathcal{O}}^{\mathcal{F}} = \{s_{t < o_k^t} \mid \begin{array}{l} t = -\tau, \dots, -1, 0, 1, \dots, \tau; \\ k = -\zeta_t, \dots, -1, 0, 1, \dots, \zeta_t. \end{array}\}.$$



Each  $s_{t < o_k^t >}$  is called a *Free Double Hierarchy Linguistic Term (FDHLT)*, where  $o_k^t$  expresses the second hierarchy linguistic term when the first hierarchy linguistic term is  $s_t$ .

*Remark 1:* For symmetry reasons, as it can be seen in Figure 1, the FDHLTs contained in  $\mathcal{O}_{-}^{-\tau} = \{s_{-\tau < o_{-\zeta_{-\tau}}^{-\tau} >}, s_{-\tau < o_{-\zeta_{-\tau+1}}^{-\tau} >}, \dots, s_{-\tau < o_{-1}^{-\tau} >}\}$  as well as in  $\mathcal{O}_{+}^{\tau} = \{s_{\tau < o_1^{\tau} >}, s_{\tau < o_2^{\tau} >}, \dots, s_{\tau < o_{\zeta_{\tau}}^{\tau} >}\}$  should be dismissed. Therefore, from now on,  $\mathcal{O}^{-\tau}$ ,  $\mathcal{O}^{\tau}$  and  $\mathcal{S}_{\mathcal{O}}^{\mathcal{F}}$  are used throughout this paper, without loss of generality, for  $(\mathcal{O}^{-\tau} \setminus \mathcal{O}_{-}^{-\tau})$ ,  $(\mathcal{O}^{\tau} \setminus \mathcal{O}_{+}^{\tau})$  and  $\mathcal{S}_{\mathcal{O}}^{\mathcal{F}} \setminus (\mathcal{O}_{-}^{-\tau} \cup \mathcal{O}_{+}^{\tau})$  respectively to simplify the notation.

*Example 1:* Let  $\mathcal{S} = \{s_{-2} = \text{"null"}, s_{-1} = \text{"bad"}, s_0 = \text{"regular"}, s_1 = \text{"good"}, s_2 = \text{"perfect"}\}$  be the first hierarchy LTS with  $\tau = 2$  and let

$$\begin{aligned} \mathcal{O}^{-2} &= \{o_{-2}^{-2} = \text{"completely"}, o_{-1}^{-2} = \text{"almost"}, \\ &\quad o_2^{-2} = \text{"close to"}\}, \\ \mathcal{O}^{-1} &= \{o_{-3}^{-1} = \text{"extremely"}, o_{-2}^{-1} = \text{"unusually"}, \\ &\quad o_{-1}^{-1} = \text{"very"}, o_0^{-1} = \text{"simply"}, o_1^{-1} = \text{"pretty"}, \\ &\quad o_2^{-1} = \text{"slightly"}, o_3^{-1} = \text{"hardly"}\}, \\ \mathcal{O}^0 &= \{o_{-2}^0 = \text{"very low"}, o_{-1}^0 = \text{"low"}, o_0^0 = \text{"medium"}, \\ &\quad o_1^0 = \text{"high"}, o_2^0 = \text{"very high"}\}, \\ \mathcal{O}^1 &= \{o_{-3}^1 = \text{"hardly"}, o_{-2}^1 = \text{"slightly"}, \\ &\quad o_{-1}^1 = \text{"pretty"}, o_0^1 = \text{"simply"}, o_1^1 = \text{"very"}, \\ &\quad o_2^1 = \text{"unusually"}, o_3^1 = \text{"extremely"}\}, \\ \mathcal{O}^2 &= \{o_{-2}^2 = \text{"close to"}, o_{-1}^2 = \text{"almost"}, \\ &\quad o_0^2 = \text{"completely"}\} \end{aligned}$$

be the respective second hierarchy LTSs for each  $s_t$ , for  $t = -2, \dots, 2$  (with  $\zeta_{-2} = \zeta_0 = \zeta_2 = 2$  and  $\zeta_{-1} = \zeta_1 = 3$ ), defining the associated FDHLTS  $\mathcal{S}_{\mathcal{O}}^{\mathcal{F}}$  represented in Figure 1. Thus, the possible linguistic assessments such as “slightly bad” or “almost perfect” can be expressed by means of FDHLTs of  $\mathcal{S}_{\mathcal{O}}^{\mathcal{F}}$  as  $s_{-1 < o_2^{-1} >}$  and  $s_{2 < o_2^1 >}$ .

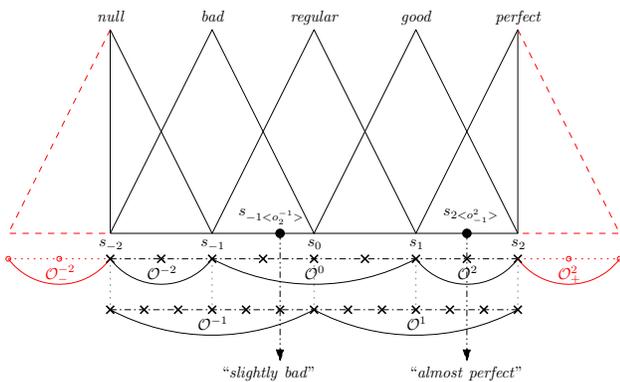


Fig. 1. FDHLTS  $\mathcal{S}_{\mathcal{O}}^{\mathcal{F}}$  from Example 1.

### III. CONCLUSIONS

Based on the weak points that HFLTSS and DHHFLTSS have in the GDM problems, a new structure is presented in this paper to capture linguistic assessments with more details.

This structure enables the decision makers to be more accurate when evaluating an alternative by means of linguistic terms.

On the one hand, Free Double Hierarchy Linguistic Term Sets are introduced as a double hierarchy LTS in which the second hierarchy LTS can be different for each term of the first hierarchy LTS. Thus, each decision maker can choose the second hierarchy LTS that better suits each linguistic term of the first hierarchy according to his/her criterion.

On the other hand, Free Double Hierarchy Hesitant Fuzzy Linguistic Elements (FDHFFLEs) and Free Double Hierarchy Hesitant Fuzzy Linguistic Term Sets (FDHFFLTSs) are defined as a useful tool to depict the hesitancy inherent in human reasoning.

Lastly, an order and a distance between FDHFFLEs are defined to enable us to present a free double hierarchy approach based on the TOPSIS method, called the FDHFFL-TOPSIS. This method is useful to sort alternatives in a GDM situation when the decision makers provide their assessments by means of free double hierarchy linguistic information in order to be more precise.

Future research is focused on two main directions: on the one hand, other methods to aggregate free double hierarchy hesitant fuzzy linguistic information will be studied as well as new measures within the set of FDHFFLTSs such as distance definitions, similarity measures or preference relations.

On the other hand, the structure of FDHFFLTSs will also be applied on the field of recommender systems among end-users that express their opinions by means of this kind of linguistic information.

### ACKNOWLEDGMENT

This research has been partially supported by the INVITE Research Project (TIN2016-80049-C2-1-R and TIN2016-80049-C2-2-R (AEI/FEDER, UE)), funded by the Spanish Ministry of Science and Information Technology and in part by the National Natural Science Foundation of China (No. 71571123, 71771155).

### REFERENCES

- [1] X. J. Gou, H. C. Liao, Z. S. Xu, F. Herrera, “Double hierarchy hesitant fuzzy linguistic term set and MULTIMOORA method: A case of study to evaluate the implementation status of haze controlling measures,” *Information Fusion* 38, pp. 22–34, 2017.
- [2] F. Herrera, E. Herrera-Viedma, L. Martínez, “A fuzzy linguistic methodology to deal with unbalanced linguistic term sets,” *IEEE Transactions on Fuzzy Systems* 16 (2), pp. 354–370, 2008.
- [3] E. Herrera-Viedma, F. Herrera, F. Chiclana, “A consensus model for multiperson decision making with different preference structures,” *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans* 32, pp. 394–402, 2002.
- [4] J. Montserrat-Adell, Z. S. Xu, X. J. Gou, N. Agell, “Free Double Hierarchy Hesitant Fuzzy Linguistic Term Sets: An application on ranking alternatives in GDM,” *Information Fusion* 47, pp.45–59, 2019.
- [5] F. Prats, L. Roselló, M. Sánchez, N. Agell, “Using L-fuzzy sets to introduce information theory into qualitative reasoning,” *Fuzzy Sets and Systems* 236 (1), pp. 73–90, 2014.
- [6] R. M. Rodríguez, L. Martínez, and F.Herrera, “Hesitant fuzzy linguistic terms sets for decision making,” *IEEE Transactions on Fuzzy Systems* 20 (1), pp. 109–119, 2012.

# Análisis de dependencias entre las variables de Arquitectura Empresarial empleando ecuaciones de relaciones difusas y su aplicación a la mejora de la toma de decisiones en las organizaciones

Annette Malleuve-Martínez,  
Daniel Alfonso-Robaina  
Facultad de Ingeniería Industrial  
U. Tecnológica de la Habana CUJAE  
Cuba  
{amalleuve,dalfonso}@ind.cujae.edu.cu

Juan Carlos Díaz-Moreno  
Jesús Medina Moreno  
Dept. de Matemáticas  
U. de Cádiz  
España  
{juancarlos.diaz,jesus.medina}@uca.es

Clemente Rubio-Manzano  
Dept. de Matemáticas  
U. de Cádiz, España  
clemente.rubio@uca.es  
Dept. Sistemas de Información  
U. del Bío-Bío, Chile  
clrubio@ubiobio.cl

**Resumen**—Actualmente la Arquitectura Empresarial es una práctica que contribuye a incrementar el desempeño de la organización a través de las Tecnologías de la Información. Los constantes cambios y la complejidad a los que se enfrentan las empresas en el mundo real constituyen desafíos para los directivos que son difíciles de manejar en el entorno empresarial.

La necesidad de disponer de una empresa saludable basada en la integración y la mejora continua del desempeño, demanda de instrumentos más eficientes que permitan evaluar la Arquitectura Empresarial a través de todas las dimensiones.

En este trabajo se propone un instrumento formal de análisis de las principales variables que soportan la Arquitectura Empresarial de una organización. Se establece y cuantifica la relación causa-efecto existente entre ellas a partir de un conjunto de reglas de dependencia difusas generadas a partir del conocimiento entregado por un conjunto de expertos de diferentes empresas. A partir de las reglas difusas obtenidas se puede, por un lado, evaluar su correcta definición desde un punto de vista teórico; y por otro, establecer prioridades de mejora teniendo en cuenta el grado de dependencia de las variables en el sistema. Para conseguir esto empleamos las ecuaciones de relaciones difusas que, además de ayudar a tratar la incertidumbre, sirven de herramienta de apoyo para la toma de decisiones y la gestión exitosa de la Arquitectura Empresarial.

**Index Terms**—Toma de decisiones, Análisis formal de reglas, Arquitectura Empresarial, Ecuaciones de Relaciones Difusas, Lógica Difusa

## I. INTRODUCCIÓN

La Arquitectura Empresarial (AE) [20] es una práctica fundamental dentro del ámbito empresarial que responde a dos desafíos permanentes, en primer lugar, los constantes cambios a los que se enfrentan las empresas y, en segundo lugar, la complejidad de enfrentarlos a corto y largo plazo [15], [17]. La AE se ha definido por muchos autores desde diferentes

enfoques: el enfoque de alineación, dirigido a conectar las estrategias de la organización con las Tecnologías de la Información para lograr un mayor rendimiento en el alcance de los planes estratégicos [8] [10] [11]; el enfoque de sistema, representación holística y distribución coherente por niveles organizativos de los procesos, los sistemas de información y la infraestructura tecnológica [4], [18]; el enfoque estratégico, describe un estado presente de la organización a través del nivel de interconexión de los procesos, las TI y las estrategias, y la conduce hacia un estado futuro o nivel superior de madurez utilizando como medios: marcos de trabajo, modelos y herramientas adaptadas a los distintos contextos empresariales [5], [14], [19].

Un aspecto fundamental dentro de la AE son los métodos, herramientas y marcos generados para la gestión de directrices, procedimientos y formas de identificarlo y la transformación en una estructura que agrega continuamente valor al negocio, es flexible y holística [1]–[3], [15]. Un desafío dentro de este ámbito es conseguir instrumentos más flexibles que permitan dar apoyo en la toma de decisiones a directivos y especialistas sobre el presente y el futuro de la empresa ante la incertidumbre y la ambigüedad generada por el gran número de elementos multifactoriales que intervienen en tales procesos.

En este trabajo proponemos un instrumento basado en lógica difusa para analizar, a través de un conjunto de ecuaciones de relaciones difusas, un total de 22 variables de AE junto a sus relaciones de dependencia generadas a partir de los datos primarios obtenidos de una lista de chequeo aplicada a un conjunto de expertos (directivos y especialistas) de la empresa. Un resultado importante de nuestro estudio es la obtención de los aspectos más relevantes que permitan mejorar el proceso de toma de decisiones en la empresa desde el enfoque de AE [13] y la posibilidad de realizar una evaluación formal sobre la corrección en la definición de las reglas de dependencia realizadas por los expertos.

La estructura del artículo es como sigue, la sección II

Partially supported by the State Research Agency (AEI) and the European Regional Development Fund (FEDER) project TIN2016-76653-P. This work has been done in collaboration with the research group SOMOS (Software-Modelling-Science) funded by the Research Agency and the Graduate School of Management of the Bío-Bío University.



presenta las variables que soportan la AE así como la relación causa-efecto entre ellas a través de un conjunto de reglas de dependencia definidas para cada etapa. En la sección III se presenta un método de evaluación de las reglas de implicación obtenidas mediante un sistema de ecuaciones de relaciones difusas. Las conclusiones y el trabajo futuro se entregan en la sección IV.

II. VARIABLES QUE SOPORTAN LA ARQUITECTURA EMPRESARIAL Y LA RELACION CAUSA-EFECTO ENTRE ELLAS

En esta sección se presentan las principales variables que soportan la AE, se establece y cuantifica la relación causa-efecto existente entre ellas a partir del conocimiento entregado por un conjunto de expertos. El resultado es un conjunto de reglas de dependencia que modelan el problema dado.

Las variables de AE se miden a través de tres etapas definidas, teniendo en cuenta las fases por las que transita el proceso de Dirección Estratégica en una organización, dicha relación conceptual(AE y Dirección Estratégica), ha sido discutida en trabajos anteriores [12]. Para cada una de las etapas se realiza dos pasos: i) definición de variables y relación causa-efecto entre ellas; ii) cuantificación de las mismas y definición de las reglas.

A. Etapa 1. Diseño Estratégico basado en Procesos

Las variables involucradas en esta de esta fase son: Equipo Estratégico (EE), la Comunicación entre actores de la organización(CEA), el Rumbo estratégico(RE), el Diagnóstico, Diseño y Rediseño de los Procesos Clave (DDRPC) y el Diagnóstico, Diseño y Rediseño de los Procesos Funcionales (DDRPF).

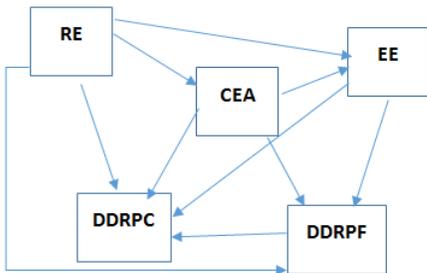


Figura 1. Diagrama de Relaciones e Inograf

A partir de estas variables se establece las relaciones causa-efecto entre las mismas (ver Figura 1) y se cuantifica dicha relación empleando la media geométrica de la puntuación otorgada(1-10) por cada experto a cada variable en la lista de chequeo [13] que se le aplicó en este caso a 9 en total por cada empresa entre directivos y especialistas principales.

Para simplificar la nomenclatura y la visualización de tablas y reglas a cada una de ellas se le ha asignado un código  $a_1, \dots, a_n$ : EE ( $a_1$ ), CEA ( $a_2$ ), RE ( $a_3$ ), DDRPC ( $a_4$ ) and DDRPF( $a_5$ ) obteniéndose las siguientes reglas de implicación.

1)  $a_2, a_3 \rightarrow a_1$

	EE	CEA	RE	DDRPC	DDRPF	TOTAL
EE				X	X	2
CEA	X			X	X	3
RE	X	X		X	X	4
DDRPC						0
DDRPF				X		1
TOTAL	2	1	0	4	3	10

Figura 2. Relación establecida entre las variables involucradas en el Diseño Estratégico basado en Procesos

- 2)  $a_3 \rightarrow a_2$
- 3)  $a_1, a_2, a_3, a_5 \rightarrow a_4$
- 4)  $a_1, a_2, a_3 \rightarrow a_5$

A partir de las cuales se obtuvo las dependencias mostradas en la Figura 1. Las reglas se deben leer de la siguiente forma:  $a_2$  y  $a_3$  tiene un efecto directo sobre  $a_1$ , en este caso, diríamos que la Comunicación entre Actores Internos y Externos junto al Rumbo Estratégico de la empresa afectará al Equipo Estratégico.

B. Etapa 2. Diseño Estratégico basado en el Enfoque de la Arquitectura Empresarial

Las variables involucradas en la etapa de Diseño Estratégico basado en el enfoque de Arquitectura Empresarial son:

- Gestión de Vigilancia en los procesos (GV).
- Gestión y automatización de los procesos(GAP).
- Capacidad de respuesta ante los cambios (CR).
- Gestión de la Información Relevante en los Procesos(GRP).
- Seguridad de la información (SI).
- Integración de la Información para la toma de decisiones estratégicas (II).
- Estructura de las aplicaciones (EA).
- Nivel de Interoperabilidad (NI).
- Aprovechamiento de las aplicaciones informáticas en los procesos (AAP).
- Inversiones en Infraestructura Tecnológica(IIT).
- Aprovechamiento de la Infraestructura Tecnológica (AIT).
- Integración entre plataformas de infraestructura tecnológica y aplicaciones informáticas (IPA).

Se realiza la misma operación que en la sección anterior, a partir de estas variables se establece las relaciones causa-efecto entre las mismas (ver Figura 3) y se cuantifica empleando la media geométrica de la puntuación otorgada(1-10) por cada experto a cada variable en la lista de chequeo [13] que se le aplicó en este caso a 9 en total por cada empresa entre directivos y especialistas principales.

Se obtuvieron las siguientes reglas y donde para simplificar la nomenclatura y la visualización de tablas y reglas a cada una de ellas se le ha asignado un código ( $b_1, \dots, b_{12}$ ): GV( $b_1$ ), GAP ( $b_2$ ), CR ( $b_3$ ), GRP ( $b_4$ ), SI ( $b_5$ ), II ( $b_6$ ), EA ( $b_7$ ), NI ( $b_8$ ), AAP ( $b_9$ ), IIT ( $b_{10}$ ), AIT ( $b_{11}$ ) y IPA ( $b_{12}$ )

- 1)  $b_1 \rightarrow b_2$
- 2)  $b_1, b_2, b_4, b_5, b_6, b_7, b_8, b_{12} \rightarrow b_3$
- 3)  $b_1, b_2, b_6, b_7, b_9, b_{11}, b_{12} \rightarrow b_4$

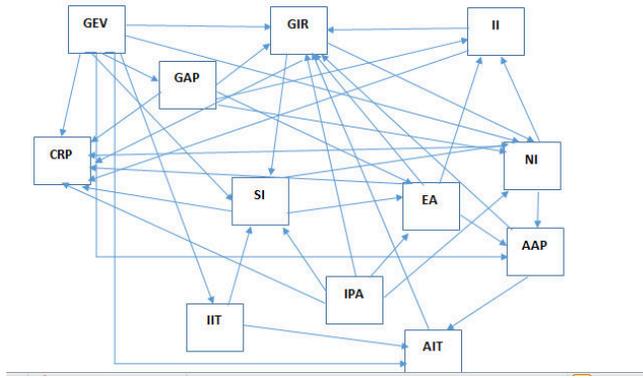


Figura 3. Relación entre las variables de la etapa2

- 4)  $b_1, b_4, b_{10}, b_{12} \rightarrow b_5$
- 5)  $b_2, b_7, b_8 \rightarrow b_6$
- 6)  $b_2, b_5, b_{12} \rightarrow b_7$
- 7)  $b_1, b_2, b_4, b_5, b_{12} \rightarrow b_8$
- 8)  $b_1, b_7, b_8 \rightarrow b_9$
- 9)  $b_1 \rightarrow b_{10}$
- 10)  $b_1, b_9, b_{10} \rightarrow b_{11}$

### C. Etapa 3. Implementación y Supervisión

Las variables involucradas en la etapa de Diseño Estratégico en la Implementación y Supervisión son:

- Liderazgo de la dirección(LD).
- Asimilación de los Cambios por los Trabajadores (ACT).
- Gestión de indicadores de eficiencia y eficacia(GIN).
- Integración de las TIC - procesos- objetivos estratégicos (IPO).
- Generación de Valor(GV).

Se realiza la misma operación que en las secciones anteriores, a partir de estas variables se establece una relación causa-efecto entre las mismas (ver Figura 5) y se cuantifica dicha relación empleando la media geométrica de la puntuación otorgada(1-10) por cada uno de los expertos en la lista de chequeo [13] que se le aplicó en este caso a 9 en total por cada empresa entre directivos y especialistas principales.

Para simplificar la nomenclatura y la visualización de tablas y reglas a cada una de ellas se le ha asignado un código  $(c_1, \dots, c_n)$ : LD  $(c_1)$ , ACT $(c_2)$ , GIN $(c_3)$ , IPO $(c_4)$ , GV $(c_5)$

- 1)  $c_1, c_4 \rightarrow c_2$
- 2)  $c_1, c_2, c_4 \rightarrow c_3$
- 3)  $c_1 \rightarrow c_4$
- 4)  $c_1, c_2, c_3, c_4 \rightarrow c_5$

### III. ANÁLISIS DE DEPENDENCIAS ENTRE VARIABLES BASADO EN ECUACIONES DE RELACIONES DIFUSAS

Para poder evaluar el conjunto de reglas definidas e interrelacionadas en la sección anterior desde un punto de vista formal se empleará un sistema de ecuaciones relacionales difusas con el objetivo de establecer una relación difusa entre las causas y los efectos y determinar si la relación está bien definida desde el prisma teórico además de obtener un grado de prioridad de cada una de ellas en el modelo de decisión.

### A. Ecuaciones de Relaciones Difusas

Las ecuaciones de relaciones difusas fueron introducidas por E. Sanchez. [16] y se asocian con el concepto de composición de relaciones difusas empleándose habitualmente para investigar aspectos teóricos y prácticos de las teoría de conjuntos difusos, como razonamiento aproximado, control automático o toma de decisiones.

En este trabajo se considera, como estructura algebraica en la que se toman los valores de las variables y de las reglas de dependencia entre ellas, el retículo completo  $([0, 1], \wedge, \vee, \odot, \rightarrow)$ , donde  $x \wedge y = \min\{x, y\}$ ,  $x \vee y = \max\{x, y\}$  y los operadores  $\odot: [0, 1] \times [0, 1] \rightarrow [0, 1]$  y  $\rightarrow: [0, 1] \times [0, 1] \rightarrow [0, 1]$  forman un par adjunto, es decir, verifican la propiedad de adjunción:

$$x \odot y \leq z \quad \text{si y solo si} \quad y \leq x \rightarrow z, \quad \text{para todo } x, y, z \in [0, 1].$$

Dado un conjunto  $V$ , el orden en  $[0, 1]$  induce un orden parcial en  $[0, 1]^V$ , definido componente a componente, que dota a  $[0, 1]^V$  de una estructura de retículo completo.

Dado un par adjunto  $(\odot, \rightarrow)$ , una ecuación de relaciones difusas viene dada por

$$R \circ X = T$$

donde  $R: U \times V \rightarrow [0, 1]$ ,  $T: U \times W \rightarrow [0, 1]$  son relaciones difusas sobre  $[0, 1]$  dadas,  $X: V \times W \rightarrow [0, 1]$  es la relación difusa incógnita, y  $R \circ X$  está definida por

$$(R \circ X)(u, w) = \bigvee \{R(u, v) \odot X(v, w) \mid v \in V\}$$

para cada  $u \in U, w \in W$ .

Una ecuación de relaciones difusas tiene solución si y solo si

$$(R \Rightarrow T)(v, w) = \bigwedge \{R(u, v) \rightarrow T(u, w) \mid u \in U\}$$

es una solución y, en este caso, es la mayor de todas. En caso contrario,  $R \Rightarrow T$  es una solución maximal de la inecuación  $R \circ X \leq T$  y, por tanto, puede considerarse como una aproximación inferior de la solución.

*Ejemplo 1:* Se considera el par adjunto  $(\odot, \rightarrow)$  sobre  $[0, 1]$ , siendo  $\odot$  el operador de Lukasiewicz, definido por  $x \odot y = \max\{0, x + y - 1\}$  y su implicación residuada, dada por  $y \rightarrow z = \min\{1, 1 - y + z\}$  para todo  $x, y, z \in [0, 1]$ . Dados los conjuntos  $U = \{u_1, u_2, u_3\}$ ,  $V = \{v_1, v_2, v_3\}$  y  $W = \{w_1\}$  y la ecuación  $R \circ X = T_1$ , donde  $R$  y  $T_1$  vienen expresadas por las matrices

$R$	$v_1$	$v_2$	$v_3$		$T_1$	$w_1$
$u_1$	0.9	0.5	0.9	y	$u_1$	0.8
$u_2$	0.2	0.9	0.7		$u_2$	0.6
$u_3$	0.8	0.6	0.9		$u_3$	0.8

se calcula  $R \Rightarrow T_1$ , que viene dada por

$R \Rightarrow T_1$	$w_1$
$v_1$	0.9
$v_2$	0.7
$v_3$	0.9



	GEV	GAP	CRP	GIR	SI	II	EA	NI	AAP	IIT	AIT	IPA	TOTAL
GEV		X	X	X	X			X	X	X	X		8
GAP			X	X		X	X	X					5
CRP													0
GIR			X		X			X					3
SI			X				X	X					3
II			X	X									2
EA			X	X		X			X				4
NI			X			X			X				3
AAP				X							X		2
IIT					X						X		2
AIT				X									1
IPA			X	X	X		X	X					5
TOTAL	0	1	8	7	4	3	3	5	3	1	3	0	38

Figura 4. Relación establecida entre las variables involucradas en el Diseño Estratégico basado en el Enfoque de la Arquitectura Empresarial

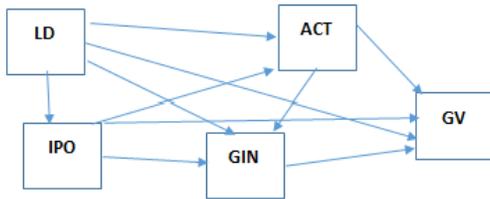


Figura 5. Relación entre las variables de la etapa3

	LD	ACT	GIN	IPO	GV	TOTAL
LD		X	X	X	X	4
ACT			X		X	2
GIN					X	1
IPO		X	X		X	3
GV						0
TOTAL	0	2	3	1	4	10

Figura 6. Relación establecida entre las variables involucradas en la Implementación y Supervisión

y se comprueba que es solución de la ecuación y, por tanto, la solución máxima.

Por el contrario, para  $T_2$  dada por

$T_2$	$w_1$
$u_1$	0.9
$u_2$	0.5
$u_3$	0.9

se obtiene que  $R \Rightarrow T_2$  y  $R \circ (R \Rightarrow T_2)$  vienen dadas por

$R \Rightarrow T_2$	$w_1$	y	$R \circ (R \Rightarrow T_2)$	$w_1$
$v_1$	1.0		$u_1$	0.9
$v_2$	0.4		$u_2$	0.5
$v_3$	0.8		$u_3$	0.8

y, por tanto,  $R \circ (R \Rightarrow T_2) < T_2$ , por lo que  $R \Rightarrow T_2$  es una solución maximal de la inecuación  $R \circ X \leq T$ .

**B. Análisis de reglas de dependencia aplicando Ecuaciones de Relaciones Difusas**

Las reglas (crisp) de dependencia definidas anteriormente (ver Figuras 1, 3, 5) en el marco teórico serán reescritas para el marco difuso asignándole un peso (valor de verdad) a cada una ellas que será evaluado mediante los datos observados

en las distintas empresas haciendo uso de las ecuaciones de relaciones difusas.

Dado una variable  $v$  (efecto) y las variables  $v_1, v_2, \dots, v_n$  (causas) denotaremos las reglas de dependencia difusas de la siguiente forma:

$$\begin{aligned} &(v_1 \rightarrow v, x_1) \\ &(v_2 \rightarrow v, x_2) \\ &\dots \\ &(v_n \rightarrow v, x_n) \end{aligned}$$

donde  $x_i$  es el valor de verdad de la regla  $(v_i \rightarrow v)$ .

Como se mostró en [6], [7] dichos pesos pueden obtenerse resolviendo la ecuación de relaciones difusas

$$v_1(E_i) \odot x_1 \vee v_2(E_i) \odot x_2 \vee \dots \vee v_n(E_i) \odot x_n = x(E_i)$$

para  $i \in \{1, \dots, m\}$

en la que los datos son los valores observados de las variables en distintas empresas  $E_1, \dots, E_m$ .

**C. Caso de estudio**

La idea consiste en dada un matriz de empresas con sus respectivos valores para las distintas variables, obtenidos a partir de la evaluación de expertos, y dado el conjunto de reglas causa-efecto establecidas en el marco teórico, evaluar mediante un conjunto de ecuaciones de relaciones difusas, los pesos (valor de verdad) de dichas reglas. Estos pesos pueden servir como indicadores de la validez de dichas reglas y de la veracidad de los datos observados en casos futuros, así como para establecer una prioridad entre las causas de un determinado efecto que quiera mejorarse aumnetando los valores de dichas causas.

Contamos con datos reales sobre seis empresas de diferentes sectores, tamaños y características denotadas  $E_1, \dots, E_6$ .<sup>1</sup> Las siguientes tablas muestran los valores observados para las variables correspondientes a cada etapa en las distintas empresas.

Para evaluar los pesos de las reglas  $a_2 \rightarrow a_1$  y  $a_3 \rightarrow a_1$ , correspondientes al efecto  $a_1$ , se considera la matriz de entrada cuyas columnas son los valores de  $a_2, a_3, a_1$ , para cada una de las empresas.

<sup>1</sup>Los nombres verdaderos de las empresas han sido omitidos por motivos de privacidad.

Variable	Id	$E_1$	$E_2$	$E_3$	$E_4$	$E_5$	$E_6$
EE	$a_1$	7.56	6.26	2.25	3.17	7.81	6.22
CEA	$a_2$	6.44	6.26	3.91	4.8	15.64	7.60
RE	$a_3$	8.78	7.19	4.20	5.23	7.59	7.82
DDRPC	$a_4$	9.00	6.32	3.10	5.30	7.66	8.02
DDRPF	$a_5$	8.78	6.16	3.83	3.88	7.70	7.63

Figura 7. Matriz de entrada para el Diseño Estratégico basado en Procesos

Variable	Id	$E_1$	$E_2$	$E_3$	$E_4$	$E_5$	$E_6$
LD	c1	8.00	6.22	4.29	3.01	7.83	7.12
ACT	c2	7.22	7.43	4.14	4.94	6.93	4.95
GIN	c3	7.56	5.11	3.24	3.36	6.46	5.87
IPO	c4	7.00	5.18	2.98	3.56	6.80	5.02
GV	c5	7.89	5.74	3.23	4.74	8.25	8.12

Variable	Id	$E_1$	$E_2$	$E_3$	$E_4$	$E_5$	$E_6$
GV	$b_1$	6.89	6.02	3.56	3.20	5.07	7.14
GAP	$b_2$	6.89	7.08	3.82	3.99	5.21	6.82
CR	$b_3$	6.56	6.55	2.36	2.70	6.81	7.78
GRP	$b_4$	8.78	7.21	3.11	3.58	6.23	7.83
SI	$b_5$	6.89	8.34	5.73	5.50	6.32	8.47
II	$b_6$	7.22	7.18	3.64	3.79	6.96	7.84
EA	$b_7$	8.33	6.78	4.28	4.92	7.96	7.95
NI	$b_8$	5.67	5.96	1.97	4.33	6.68	4.84
AAP	$b_9$	7.11	6.54	3.56	4.03	5.64	6.64
IIT	$b_{10}$	8.11	7.20	3.70	4.55	6.26	4.13
AIT	$b_{11}$	7.78	7.50	3.04	4.20	6.68	6.40
IPA	$b_{12}$	7.22	7.69	2.42	4.55	5.82	5.38

Figura 8. Matriz de entrada para el Diseño Estratégico basado en el Enfoque de la Arquitectura Empresarial

$$M = \begin{bmatrix} a_2 & a_3 & a_1 \\ 0.644 & 0.878 & 0.756 \\ 0.626 & 0.719 & 0.626 \\ 0.391 & 0.42 & 0.225 \\ 0.481 & 0.523 & 0.317 \\ 0.564 & 0.759 & 0.781 \\ 0.76 & 0.782 & 0.622 \end{bmatrix}$$

A continuación extraemos de  $M$  las matrices  $R$  (matriz de causas) y  $T$  (matriz de efecto)

$$R = \begin{bmatrix} 0.644 & 0.878 \\ 0.626 & 0.719 \\ 0.391 & 0.42 \\ 0.481 & 0.523 \\ 0.564 & 0.759 \\ 0.76 & 0.782 \end{bmatrix} \quad T = \begin{bmatrix} 0.756 \\ 0.626 \\ 0.225 \\ 0.317 \\ 0.781 \\ 0.622 \end{bmatrix}$$

Se calcula entonces

$$R \Rightarrow T = \begin{bmatrix} 0.834 \\ 0.794 \end{bmatrix}$$

$$\text{Dado que } R \circ (R \Rightarrow T) = \begin{bmatrix} 0.672 \\ 0.513 \\ 0.225 \\ 0.317 \\ 0.553 \\ 0.594 \end{bmatrix} < T$$

$R \Rightarrow T$  es una solución maximal de la inecuación  $R \circ X \leq T$ . Así, se le puede asignar a la regla  $a_2 \rightarrow a_1$  el valor de verdad 0.834 y a la regla  $a_3 \rightarrow a_1$ , el valor de verdad 0.794. Estos resultados ponen de manifiesto que los valores de verdad obtenidos a partir de los datos suministrados por los expertos

son muy cercanos a los establecidos desde el punto de vista teórico. Estos resultados además pueden usarse para establecer la prioridad de mejora entre las variables cuyos valores sean bajos para incrementar el desempeño de la AE. Por ejemplo, si se quiere mejorar el valor de la variable efecto)  $a_1$ , se puede priorizar la mejora del valor de la variable (causa)  $a_2$ , cuyo peso en la relación causa-efecto es mayor, frente a la variable (causa)  $a_3$ .

Para automatizar tal proceso se ha creado una aplicación software que permite cargar las matrices de empresas y aplicar diferentes implicaciones. Así el usuario puede determinar si las relaciones entre las variables y pesos establecidos entre ellas está modelado correctamente desde el punto de vista matemático. La herramienta junto a un manual de usuario se encuentra públicamente disponible en la siguiente dirección web:

[https://dsi.face.ubiobio.cl/somos/AE\\_data\\_analysis/](https://dsi.face.ubiobio.cl/somos/AE_data_analysis/)

La herramienta cuenta con una ventana de visualización de empresas y sus efectos (ver Figura 9-1). Al pulsar sobre la empresa aparecerán los datos asociados a la empresa y al pulsar sobre un efecto se aplicará dicho efecto a la lista de empresas cargadas (ver Figura 9-2). Por ejemplo a partir de los datos mostrados en la Figura 8 se crea una ventana con los datos de la matriz  $M$  (definida previamente). El sistema automáticamente crea  $R$  y  $T$  y computa  $X$  (ver Figura 9-3), obteniendo la aproximación  $T'$  que se visualiza junto a  $T$  original con el objetivo de comprobar la diferencia entre ambas (ver Figura 9-4) y comprobar si el modelado realizado por los expertos es correcto desde un punto de vista teórico.

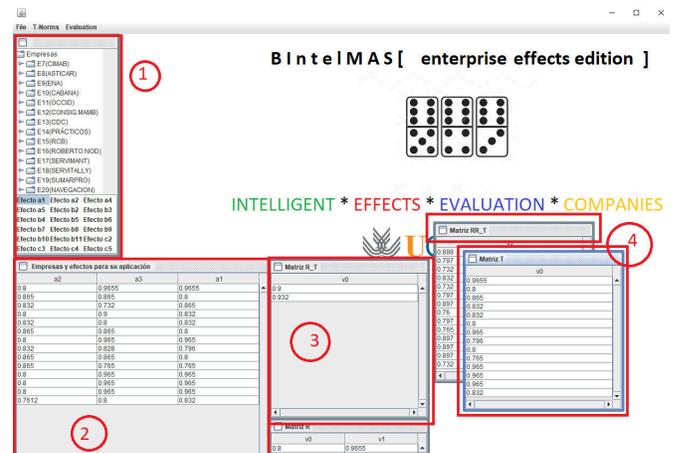


Figura 9. Ventana principal de la aplicación de análisis de dependencias de variables AE



#### IV. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se ha introducido la importancia de disponer de una buena Arquitectura Empresarial para garantizar desempeño de la organización a través de las Tecnologías de la Información. Se han definido las principales variables que las sustentan así como las relaciones de dependencia establecidas por un conjunto de expertos. Con el objetivo de analizar dicho modelo se ha propuesto las ecuaciones de relaciones difusas como un instrumento para medir la calidad de las reglas de dependencia fijadas. El resultado ha sido una herramienta que permite apoyar la toma de decisiones a partir de los datos actuales de un conjunto de empresas.

Como trabajo futuro se pretende obtener la prioridad de mejora que cada una de las variables tienen en la Arquitectura Empresarial con el objetivo de trazar un posible plan de actualización si así lo requiere la empresa.

#### REFERENCIAS

- [1] F.Ahlemann, E. Stettiner, M. Messerschmidt, C. Legner. Strategic enterprise architecture management: challenges, best practices, and future developments?. pp.85-110, Springer Science & Business Media, 2012.
- [2] S.Aier, S. Kurpjuweit, J. Saat, R. Winter. Enterprise architecture design as an engineering discipline. AIS Transactions on Enterprise Systems, vol. 1, pp. 36-43, 2009.
- [3] S. Buckl, A. M. Ernst, M. F. Lankes, C. M. Schweda. Enterprise architecture management patterns? exemplifying the approach. Enterprise Distributed Object Computing Conference, 2008. EDOC08. 12th International IEEE, pp. 393-402. IEEE. 2008.
- [4] M. Berrada y B. Bounabat. Business Modeling of Enterprise Architecture Based on Multi-Agent System International Journal of e-Education, e-Business, e-Management and e-Learning, vol. 14, pp. 472, 2013.
- [5] C. Braun and R. Winter. Integration of IT service management into enterprise architecture? En Proceedings of the 2007 ACM symposium on Applied computing, pp. 1215-1219. ACM 2007.
- [6] M. E. Comejo, J.C. Díaz-Moreno, J. Medina. Multi-adjoint Relation Equations: A Decision Support System for Fuzzy Logic. International Journal of Intelligent Systems, 32(8), 778-800, 2017.
- [7] J.C. Díaz, J. Medina. Multi-adjoint relation equations: Definition, properties and solutions using concept lattices. Information Sciences, 253, 100-109, 2013.
- [8] K. Hinkelmann, A. Gerber, D. Karagiannis, B. Thoense, A. Van der Merwe, R. Woitsch. A new paradigm for the continuous alignment of business and IT: Combining enterprise architecture modelling and enterprise ontology Computers in Industry, vol. 79, pp. 77-86, 2016.
- [9] W. Bandler, L. Kohout. Semantics of implication operators and fuzzy relational products. Int. J. Man-Machine Studies, 12:89-116, 1980.
- [10] J. Lapalme. Three schools of thought on enterprise architecture IT professional, vol. 14, pp. 37-43, 2012.
- [11] M. Lankhorst. Enterprise architecture at work: Modelling, communication and analysis. Springer, 2009.
- [12] A. Malleuve, D. Alfonso, J. Lavandero. Estudio del comportamiento de variables para la integración del sistema de dirección de la empresa con enfoque de Arquitectura Empresarial. Dyna Colombia, 84(203):349-355, 2017.
- [13] A. Malleuve. Integration of Management System with Enterprise Architecture approach in a communications enterprise unpublished.
- [14] P. Johnson, M. Ekstedt, E. Silva, L. Plazaola. Using enterprise architecture for cio decision-making: On the importance of theory. Second Annual Conference on Systems Engineering Research. 2004.
- [15] J. Schekkerman. How to survive in the jungle of enterprise architecture frameworks: Creating or choosing an enterprise architecture framework? pp. 2-33, Trafford Publishing, 2004.
- [16] E. Sanchez. Resolution of composite fuzzy relation equations. Information and Control, 30(1):38-48, 1976.
- [17] L. Urbaczewski, S. Mrdalj. A comparison of enterprise architecture frameworks Issues in Information Systems, vol. 7, pp. 18-23, 2006.
- [18] F. B. Vernadat. Interoperable enterprise systems: Principles, concepts, and methods Annual reviews in Control, vol. 31, pp. 137-145, 2007.
- [19] R. Winter, R. Fischer. Essential layers, artifacts, and dependencies of enterprise architecture Enterprise. Distributed Object Computing Conference Workshops, 2006. EDOCW 06. 10th IEEE International pp. 30-30. IEEE, 2006.
- [20] J. A. Zachman. A framework for information systems architecture. IBM Systems Journal, vol. 26, pp. 276-292, 1987.

# Supporting university career services by means of a multi-criteria decision-aiding system

J. Nguyen, G. Sánchez-Hernández, A. Armisen, N. Agell, X. Rovira, and C. Angulo

*Universitat Politècnica de Catalunya (BarcelonaTech), Spain  
University of Vic, Central University of Catalonia, Spain  
ESADE Business School, Ramon Llull University, Spain*

**Abstract**—This paper is a reduced version of the one published in [1]. We introduce a linguistic multi-criteria decision-aiding model to match college students with internships. It considers a fuzzy ordered weighted averaging (FOWA) operator to capture the inherent uncertainty and vague nature of personnel selection processes. A software tool is implemented to assess the match between internship requirements and student’s preferences by means of linguistic descriptions, and propose positions according to student preferences. A reduced list of internships is presented to help students to decide where to focus their attention.

**Index Terms**—Decision support systems, Multi-criteria decision-aiding, Hesitant fuzzy linguistic terms, Fuzzy OWA operator, Personnel selection problem

## I. INTRODUCTION

Organizations are challenged daily to make complex decisions. These decisions can be subjective, uncertain, and imprecise [2]. For global organizations, human resources personnel selection can be challenging as candidates are diverse and vary in level of knowledge of a topic. Their knowledge is difficult to qualify and changes frequently [3]. Personnel selection is subjective in nature with regards to assigning crisp values to the job requirements and evaluating candidate qualifications. Previous studies have extended MCDA methods to this problem to address its fuzziness [4], [5].

The aim of this paper is to introduce a practical decision support system to assist students with identifying internships related to their interests when searching for a position for the first time. A real case example is implemented with student and job information provided by a university’s career services office. In terms of feature representation, the novelty of the application is two-fold. First, the requirements of a position are extracted in an implicit manner and represented via linguistic terms. Second, linguistic terms are also considered to represent students’ interests. The model considered for linguistic descriptions is the hesitant fuzzy linguistic model. This model was introduced by Rodriguez et al. in [6] and further developed in [7].

The rest of the paper is structured as follows. First, we discuss tools used in the design of a linguistic MCDA system which include linguistic descriptors, and fuzzy matching and aggregation. Next, we describe the proposed decision support system, provide a real case example, discuss conclusions future research directions.

## II. METHODOLOGY

Internships may be a student’s first experience searching for a position, therefore, it may be difficult for him to express his preferences as a single label. Given this uncertainty, we propose the application of Hesitant Fuzzy Linguistic Term Set (HFLTS) [7] to manage the need for several labels to define preferences. The approach proposed in this paper relies on the use of linguistic terms based on a qualitative absolute order-of-magnitude model [8] that allows us to deal with the imprecision and hesitance involved in decision processes. We will express this model by means of HFLTS introduced by Rodriguez et al. [7].

Let  $\mathbb{S}_n$  be a finite set of totally ordered basic terms,  $\mathbb{S}_n = \{B_0, \dots, B_n\}$ , with  $B_0 < \dots < B_n$  and the hesitant fuzzy linguistic terms set,  $H_{\mathbb{S}_n}$ , be the set of all consecutive linguistic basic terms of  $\mathbb{S}_n$ , i.e.  $B_{ij} = \{x \in \mathbb{S}_n \mid B_i \leq x \leq B_j\} \forall i, j \in \{0, \dots, n\}$ , with  $i \leq j$ . In general, each term corresponds to a linguistic label, with  $B_0$  being the term “None”. For simplicity, we will denote the singleton  $B_{ii} = B_i$ . The total order in the set of basic terms,  $\mathbb{S}_n$ , allows us to define a total order in  $H_{\mathbb{S}_n}$  based on the lexicographic order such that: given two linguistic terms,  $B_{ij}, B_{i'j'} \in H_{\mathbb{S}_n}$ ,  $B_{ij} \leq_L B_{i'j'}$ , iff  $i < i'$  or  $i = i'$  and  $j \leq j'$ . From this point forward, we consider  $H_{\mathbb{S}_n}^*$ , a subset of  $H_{\mathbb{S}_n}$ , which corresponds to the HFLTS obtained when the set of basic elements is  $\mathbb{S}_n^* = \{B_1, \dots, B_n\}$ . In addition, in  $H_{\mathbb{S}_n}$  we consider the subset inclusion to define the relation “to be more precise or equal to”. We say that  $B_{ij}$  is more precise or equal to  $B_{i'j'}$ ,  $B_{ij} \preceq B_{i'j'}$ , if and only if,  $B_{ij} \subseteq B_{i'j'}$ , i.e.  $i' \leq i$  and  $j \leq j'$ .

HFLTS can be used to compare individual’s preferences to object’s attributes to capture imprecision in decision processes. To this end, we will define an operator matching two basic terms and extend it to the entire set of HFLTS catching all possible combinations of hesitancy in both descriptions.

*Definition 2.1:* The fuzzy matching operator is the map  $\ast : H_{\mathbb{S}_n} \times H_{\mathbb{S}_n}^* \rightarrow H_{\mathbb{S}_n}$  such that:

- 1)  $\forall B_i \in \mathbb{S}_n$  and  $\forall B_j \in \mathbb{S}_n^*$ ,  $B_i \ast B_j = B_{\min(n, n-(j-i))}$ ,
- 2)  $\forall B_{ij} \in H_{\mathbb{S}_n}$  and  $\forall B_{i'j'} \in H_{\mathbb{S}_n}^*$ ,  
 $B_{ij} \ast B_{i'j'} = \bigsqcup \{B_k \ast B_l, i \leq k \leq j \text{ and } i' \leq l \leq j'\}$ .

Note that, 2. coincides with 1.  $\forall B_i \in \mathbb{S}_n$  and  $\forall B_j \in \mathbb{S}_n^*$ .



*Example 2.1:* Let us consider that a candidate's preferences are represented by  $H_{S_n^*}$  and the features of each position are represented by  $H_{S_n}$ , then given the previously considered HFLTS,  $H_{S_n^*}$ , with  $n = 3$ , the results of the fuzzy matching operator for the basic terms are shown in Table I.

TABLE I  
FUZZY MATCHING OPERATOR \*

*	Low ( $B_1$ )	Medium ( $B_2$ )	High ( $B_3$ )
None ( $B_0$ )	Medium ( $B_2$ )	Low ( $B_1$ )	None ( $B_0$ )
Low ( $B_1$ )	High ( $B_3$ )	Medium ( $B_2$ )	Low ( $B_1$ )
Medium ( $B_2$ )	High ( $B_3$ )	High ( $B_3$ )	Medium ( $B_2$ )
High ( $B_3$ )			

Given two  $k$ -dimensional different vectors,  $X = (X_1, \dots, X_k) \in (H_{S_n})^k$  and  $Y = (Y_1, \dots, Y_k) \in (H_{S_n^*})^k$ , we analyze the existing matching between these vectors, comparing each component, by means of the fuzzy matching operator  $*$ , and a FOWA (fuzzy ordered weighted average).

*Definition 2.2:* Given  $X \in (H_{S_n})^k$  and  $Y \in (H_{S_n^*})^k$ , the fuzzy matching between  $X$  and  $Y$  is defined as:

$$X * Y = (X_1 * Y_1, \dots, X_k * Y_k) \in (H_{S_n})^k$$

For our purpose, we consider the regular increasing monotone (RIM) function, introduced by Yager [9], guided by the linguistic quantifier 'most of'.

The proposed system caters to the interests of students rather than the requirements of a position to help students identify internship offerings which best match their individual interests. To start, profiles are created for each student and position to represent preferences and features of each, respectively. Preferences are student interests elicited from each student and features are requirements determined from each position. To obtain these preferences and features, Latent Dirichlet allocation (LDA) is applied to student curriculum vitae and internship descriptions. Originally developed by Blei et al. [10], LDA is an unsupervised topic modeling method. Student's preferences are compared with each position's features. The outputs of the decision-making model are internship positions sorted in a manner which represents students preferences.

### III. A REAL CASE EXAMPLE

In this real case example, the 2016 internship program for the Bachelor of Business Administration at ESADE Business School in Barcelona, Spain, was used to apply the proposed method. The data set was composed of 275 student resumes and 1063 available internships. All resumes and internship descriptions in English were considered. The final data set consisted of 275 students and 549 internships. Student information was limited to the resumes provided for the purposes of the 2016 internship cycle. Internship positions included national and international postings.

To evaluate the advantages and drawbacks of our proposed method, we compare it to: 1) TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution) and 2) a ranking method based on Hellinger distance. In comparison to the

TOPSIS method, our method recommended zero positions to at most 40 users while the TOPSIS method recommended zero positions to at most 55 users, demonstrating that more students received recommendations with our method. The results obtained from a comparison with the Hellinger distance show that the Hellinger method recommended 65 or more positions to the majority of the students, while our method provided more reasonable (i.e.140) recommendations to most students.

### IV. CONCLUSION

In this paper, a new method for sorting internship postings according to student interests has been introduced. This methodology improves existing methods in several ways. First, it proposes to perform a matching between students and internships from the perspective of the job candidate rather than the position. This is the reverse of the more popular matching to find the best candidate for a position. Second, the method considers a FOWA operator in the matching to capture the inherent uncertainty of personnel selection. Lastly, the interests and features of the students and positions are represented as HFLTS, reflecting human tendency to opine with imprecision and hesitation in making decisions. Our methodology can be extended to both sides of the general personnel assignment problem making the process more efficient. A position which is closely aligned with the interests of a job candidate may lead to better job loyalty. Therefore, as future research, we propose to adapt our methodology to other personnel selection environments like headhunting firms, online job boards, and industry human resources to uncover the interests of a job candidate prior to the interview process.

### REFERENCES

- [1] Jennifer Nguyen, G Sánchez-Hernández, Albert Armisen, Núria Agell, Xari Rovira, and Cecilio Angulo. A linguistic multi-criteria decision-aiding system to support university career services. *Applied Soft Computing*, 67:933–940, 2018.
- [2] Rosana Montes, Ana M Sánchez, Pedro Villar, and Francisco Herrera. A web tool to support decision making in the housing market using hesitant fuzzy linguistic term sets. *Applied Soft Computing*, 35:949–957, 2015.
- [3] Mark T Maybury. Discovering distributed expertise. *Regarding the Intelligence in Distributed Intelligent Systems MITRE*, 2007.
- [4] Alecos Kelemenis and Dimitrios Askounis. A new topsis-based multi-criteria approach to personnel selection. *Expert systems with applications*, 37(7):4999–5008, 2010.
- [5] Alvydas Baležentis, Tomas Baležentis, and Willem KM Brauers. Personnel selection based on computing with words and fuzzy multimooora. *Expert Systems with applications*, 39(9):7961–7967, 2012.
- [6] Rosa M Rodríguez, Luis Martínez, and Francisco Herrera. Hesitant fuzzy linguistic term sets. In *Foundations of Intelligent Systems*, pages 287–295. Springer, 2011.
- [7] Rosa M Rodríguez, Luis Martínez, and Francisco Herrera. Hesitant fuzzy linguistic term sets for decision making. *IEEE Transactions on Fuzzy Systems*, 20(1):109–119, 2012.
- [8] Louise Travé-Massuyès, Francesc Prats, Mónica Sánchez, and Núria Agell. Relative and absolute order-of-magnitude models unified. *Annals of Mathematics and Artificial Intelligence*, 45(3):323–341, 2005.
- [9] Ronald R Yager. Quantifier guided aggregation using owa operators. *International Journal of Intelligent Systems*, 11(1):49–73, 1996.
- [10] David M Blei, Andrew Y Ng, and Michael I Jordan. Latent dirichlet allocation. *Journal of machine Learning research*, 3(Jan):993–1022, 2003.



**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 7:  
APLICACIONES II







# Estudio empírico sobre el tratamiento de la sinonimia en los razonamientos vagos

Gael Velasco Benito

Dpto. de Filosofía y Antropología  
Universidad de Santiago de Compostela  
gael.velasco@gmail.com

Alberto Bugarín

Centro Singular de Investigación en  
Tecnoloxías da Información (CiTIUS)  
Universidad de Santiago de Compostela  
alberto.bugarin.diz@usc.es

Alejandro Sobrino

Dpto. de Filosofía y Antropología  
Universidad de Santiago de Compostela  
alejandro.sobrino@usc.es

**Resumen**—Existen dos alternativas relacionadas con la manera en la que se debe formalizar los términos vagos de nuestro lenguaje para su correcta implementación en un lenguaje de programación lógica. Una opción es hacer preciso el contenido semántico (es decir, eliminar la vaguedad de un término lingüístico estableciendo límites claros), y otra opción es mantener las propiedades vagas del lenguaje (a pesar de las muchas complicaciones que surgen a raíz de ello). En este artículo ofrecemos un argumento empírico a favor de esta última postura, y analizamos la posibilidad de desarrollar una aproximación al razonamiento impreciso de naturaleza más bien lingüística que numérica. Los resultados obtenidos apoyan esta posibilidad, y ofrecen evidencias según las cuales algunos de los problemas más básicos que pueden presentarse al implementar un método de resolución vago en computación pueden resolverse haciendo uso de la conocida como “aproximación de grado”.

**Palabras clave**—vaguedad; aproximación de grado; razonamiento natural; computación con palabras.

## I. INTRODUCCIÓN

En el campo de la computación con lenguaje natural parece existir un acuerdo general sobre el hecho de que el lenguaje humano es, esencialmente, vago, y que dicha vaguedad influye de manera directa en nuestra manera de razonar. Este comportamiento difiere del procesamiento del lenguaje natural clásico, que usa algoritmos precisos. Tradicionalmente, la vaguedad se ha contrapuesto a la precisión: “*We are able to conceive precision; indeed, if we could not do so, we could not conceive vagueness, which is merely the contrary of precision*” [19:5]. Esta diferencia es la que ha generado más dificultades a la hora de desarrollar un sistema automático computacional que sea capaz de procesar y manipular de manera correcta los términos vagos.

Frente a este problema, una primera aproximación consiste en tratar la vaguedad como un defecto que debe ser eliminado de nuestro lenguaje [19]. Los límites entre las extensiones positivas y negativas de un término vago (es decir, los parámetros que permiten clasificar un elemento como perteneciente o no a la categoría establecida por una palabra) podrían ser descubiertos y aplicados de manera precisa, obteniendo así un formalismo lógico menos imperfecto que el lenguaje natural y que podría llegar a sustituirlo en cualquier ámbito. Las aproximaciones más comunes a esta postura hacen uso de la lógica bivalente o de dos valores (algo es bello o no lo es,

una persona es joven o no lo es, etc.), al considerarla como la lógica más sencilla y que mejor representa la realidad [18]. En esta tradición semántica supervaluacionista de Fine [6] y Dummett [3] se propone la posibilidad de que a cualquier término lingüístico  $P$  se le puede (y debe) aplicar una serie de precisiones (*precisifications* en inglés) que permitan señalar qué elementos pertenecen a las extensiones positivas y negativas de  $P$ .

Existen varios argumentos en contra de esta aproximación, señalando la obtención de resultados contraintuitivos y poco naturales como su principal argumento, e indicando que existen otras lógicas fuera de la lógica bivalente mejores para el estudio formal de la vaguedad [21]. La lógica multivalorada aporta resultados más próximos a la realidad, utilizando una serie de grados numéricos que permiten una clasificación más fina de los elementos pertenecientes al dominio de una palabra. El problema está en que si estos grados no se utilizan de manera aproximada [4], el modelo que se obtiene es un modelo que también trata con precisión la vaguedad (aunque con varios —o infinitos— límites en lugar de solo uno), arrastrando consigo todos los problemas inherentes a estas aproximaciones. Sería, pues, necesario buscar un formalismo gradual no numérico, capaz de representar el significado de los términos vagos sin, para ello, modificar su forma de uso o su contenido semántico.

Tomando como punto de partida la opinión de que la acción de precisar los términos vagos es una solución que, aunque funciona como aproximación general al problema, en ciertos casos puede llevar a resultados poco intuitivos, en este trabajo estudiamos la posibilidad de una alternativa no precisa basada en las relaciones semánticas ya existentes en nuestro lenguaje.

La organización del artículo es la siguiente. En la Sección II introducimos los fundamentos teóricos del problema, así como la conveniencia práctica de utilizar la aproximación de grado como base. En las Secciones III y IV presentamos el estudio empírico llevado a cabo en el ámbito de los razonamientos vagos. En la Sección V se discuten los resultados obtenidos, los cuales sugieren una posible correlación entre los juicios valorativos humanos en un razonamiento y la distancia entre grados en una escala.

## II. TRATAMIENTO GRADUAL NO PRECISO DE LOS RAZONAMIENTOS VAGOS

Uno de los intentos más importantes y exitosos de tratar la vaguedad desde una perspectiva computacional es la conocida como Computación con Palabras [25], [26], un sistema que pretende simplificar la computación de problemas complejos que involucran lenguaje impreciso o vago y facilitar su implementación. Su principal aportación es la introducción del concepto de variable lingüística, así como la idea de que en computación se puede trabajar directamente con palabras (o percepciones), y no únicamente con valores numéricos o medidas. Siguiendo sus directrices, un problema tratado mediante la Computación con Palabras estará expresado en lenguaje natural, de manera que los resultados obtenidos serán, a su vez, proposiciones o palabras.

El inconveniente reside en que, aunque las bases de la Computación con Palabras son claras, el proceso de resolución no es lingüístico, sino numérico, dado que reduce las proposiciones de entrada a expresiones propias de la Lógica Difusa y las manipula hasta conformar un resultado preciso que, en un paso posterior, es transformado de nuevo a lenguaje natural. Inevitablemente, el contenido semántico de las expresiones vagas se volverá preciso, y por ende modificado. A pesar de las múltiples ventajas propias de esta aproximación, consideramos que en el caso de los razonamientos vagos sería conveniente buscar un método alternativo que nos permitiera conservar el significado de las palabras tal y como lo percibimos los seres humanos durante todos los pasos. Creemos que, de ser esto posible, las conclusiones obtenidas serían más coherentes y naturales, y que el proceso de resolución sería más sencillo de comprender para aquellas personas no versadas en la computación o en la Lógica.

En la bibliografía pueden encontrarse diversos argumentos en contra de la acción de precisar de los términos vagos, todos los cuales coinciden al defender que la vaguedad no es un defecto superficial que pueda corregirse trazando límites precisos, sino una característica semántica de nuestro lenguaje (una primera aproximación al respecto puede encontrarse en [23]). Por solo citar algunos casos, en [24] la acción de volver preciso lo que es vago es criticada al argumentar que, aunque pudiésemos definir reglas explícitas que formalizasen la vaguedad, estas no servirían para explicar el significado de un término vago a alguien que no esté familiarizado con él (es decir, estas reglas no serían “informativas”). De forma similar, en [1] se apoya esta postura al argumentar que las condiciones de verdad de las palabras vagas solo pueden ser gobernadas por reglas igualmente vagas. Y otros autores como Edgington [4], aunque apoyan el uso de la Lógica Difusa en el desarrollo de una teoría formal de la vaguedad, advierte que ésta nunca podría ser utilizada de manera precisa, sino como valores aproximados que permitan construir un modelo aproximado del problema y no den lugar a infinitos estados precisos.

En el presente artículo partiremos de las ideas contenidas en [17], [22], donde se propone como alternativa la utilización

de las relaciones lingüísticas ya existentes en nuestro lenguaje, las también conocidas como “relaciones semánticas”. Algunos ejemplos serían la sinonimia (igualdad de significado, como por ejemplo “escaso” y “poco”), la antonimia (significado opuesto o contradictorio, como es el caso de “afilado” y “romo”) o la hiperonimia (inclusión de significados, como es el caso de “libro”, que es un hiperónimo de “novela”).

Introducir este tipo de relaciones en un lenguaje de programación lógico sería una ventaja enriquecedora y sustancial, dado que la mayoría de ellos se limita a interpretar relaciones sintácticas, y no semánticas. Utilizando como ejemplo el lenguaje Prolog, supongamos que tenemos un programa con los siguientes hechos y reglas donde  $P(x)$  denota “ $x$  posee la propiedad  $P$ ” (es decir, “la pasta está rica”, “el sushi está bueno”, etc.) y  $menu(X) :- rico(X)$  representa una norma según la cual “el elemento designado por  $X$  estará en el menú si  $X$  cumple con un requisito, a saber: que  $X$  cumpla la propiedad de estar rico”:

*rico(pasta).*

*bueno(sushi).*

*delicioso(paella).*

*menu(X) :- rico(X).*

En este caso, la respuesta a la pregunta “¿Qué hay en el Menú?” es clara: “ $X = pasta$ ”.

La solución, aunque válida, se nos antoja incompleta dado que aunque el sushi y la paella, según el programa, no estén “ricos”, no es del todo coherente afirmar que no cumplen con el requisito necesario para aparecer en el Menú. Pero tampoco podemos afirmar lo contrario (que el sushi y la paella cumplen el requisito al mismo nivel que la pasta).

Lo que haría falta sería que el programa supiese que estos tres adjetivos están semánticamente relacionados entre sí, y cuál es el nivel o tipo de sinonimia de cada uno con respecto a los otros dos. De esta forma, podría presentar más de una respuesta, aunque matizando que algunas de ellas tienen un grado de validez superior al de las otras.

A este respecto se han realizado varios intentos basados en un tratamiento preciso de la vaguedad ([7], [11], [13], entre otros). Muchos de estos métodos parten de la idea de asignar un valor numérico a cada propiedad definida (por ejemplo, asignando los valores 1 y 0,8 a “pasta” y “sushi”, respectivamente, con respecto a la propiedad “estar rico”), y utilizar esa clasificación para ordenar las respuestas de más a menos válida, cada una de ellas señalada con un número entre 0 y 1 que determina cuán válida es con respecto a la pregunta hecha al programa. Estos trabajos logran con éxito aumentar la capacidad expresiva de lenguajes como Prolog, pero como ya hemos mencionado anteriormente, esta manera de tratar la vaguedad tiene sus problemas, siendo el principal de todos que asignan valores numéricos arbitrarios sin una base sólida que los justifique, los cuales forman a su vez una serie de infinitos estados precisos que simulan un comportamiento semántico muy distinto al de las palabras vagas de nuestro lenguaje.

Las relaciones lingüísticas no presentarían estas dificultades, aunque un método así será más difícil de implementar a causa



de las diferencias inherentes entre seres humanos y sistemas computacionales. Las relaciones semánticas más útiles en el caso de los razonamientos vagos son las de sinonimia y antonimia a causa de sus paralelismos directos con los conceptos de igualdad y negación implicados en los procesos resolutivos de lenguajes de programación Prolog; es decir, el emparejamiento o *matching* y la resolución por refutación.

Una posible solución se basa en la aproximación conocida como “aproximación de grado” [8]–[10]. Según esta alternativa, los elementos pertenecientes ciertas categorías gramaticales como la de los adjetivos estarían asociados a una entidad abstracta, el grado  $d$ , que representaría el valor o cantidad de la propiedad dada por esos elementos. Estos grados estarían a su vez ordenados en escalas, elementos lingüísticamente relevantes que pueden definirse por medio de tres parámetros: un conjunto de grados, una relación de orden que ordena dicho conjunto, y una “dimensión” (también llamada “medida”) que establece cuál es la propiedad real representada por la escala (peso, tamaño, edad, etc.). Así pues, todos los elementos de la escala están relacionados, de forma que dos elementos cualesquiera que pertenezcan a ella podrán compararse entre sí (siendo uno mayor que el otro). No hay que perder de vista que la aproximación de grado, en su forma clásica, impone en sus escalas un determinado grado “estándar de comparación” o “normal” que sirve como límite claro entre aquellos grados que representan de manera positiva la dimensión de la escala y aquellos que no. Dado el tratamiento no vago de este formalismo, en el estudio no adoptaremos dicha medida, centrándonos únicamente en la existencia de los grados y de una relación de orden total que nos permite ordenarlos de mayor a menor dentro de una escala.

### III. HIPÓTESIS DE TRABAJO

La principal hipótesis sobre la que trabajamos tiene su apoyo teórico en [15], donde el contenido semántico de un término lingüístico se subdivide en dos categorías: significado “cognitivo” y significado emotivo o “no cognitivo”. En términos generales, esta clasificación respondería a dos facultades psicológicas distinguibles en el uso del lenguaje: una intelectual, lógica, y otra intuitiva o emotiva. Sin embargo, muchos de los factores que definen el significado no cognitivo de una palabra no están realmente relacionados con lo que se suele considerar como “significado” o “contenido semántico”, sino con otros elementos de carácter pragmático tales como la aceptabilidad estilística o social (por ejemplo, el significado no cognitivo determinaría el carácter formal o coloquial de una palabra, o si existe algún contexto en que dicha palabra no puede o no debe ser usada). Por ese motivo, Lyons determina que el tratamiento formal de la sinonimia, así como su aplicación a cualquier proposición natural, debe restringirse únicamente a su contenido cognitivo.

Volviendo a la aproximación gradual, el significado de una palabra, una vez dejado a un lado cualquier implicación no lógica y centrándonos únicamente en el significado cognitivo, estaría representado por los grados. En el caso de un lenguaje de programación Prolog, estos grados estarían representados

por las mismas palabras, las cuales conformarían una escala lingüística (en el sentido dado en [12] de “un conjunto de alternantes lingüísticos, o expresiones contrastivas de la misma categoría gramatical, que pueden ordenarse en un orden lineal por grados de informatividad o fuerza semántica”). De esta manera, si prescindimos del formalismo bivalente, inherente de las aproximaciones de grado clásicas, serían pues estas palabras, y su relación total con el resto de palabras de la misma escala, los únicos elementos necesarios para representar el contenido lógico de los términos y su influencia en las condiciones de verdad de un razonamiento vago.

En consecuencia, si Prolog u otros lenguajes de programación pudiesen interpretar de manera correcta estos grados, y a su vez pudiesen mostrarlos al usuario mediante el uso del lenguaje natural, podrían alcanzarse soluciones no precisas para razonamientos en los que intervienen términos vagos, ya que las escalas son elementos que Prolog y otros lenguajes interpretan y manejan con facilidad.

La pregunta que se pretende estudiar es esta: si tenemos una serie de premisas conectadas entre sí por sinónimos de las cuales se infiere una conclusión, ¿existe una relación directa entre el juicio de valor que, de media, realizaría un ser humano acerca de dicha conclusión, y la separación que existe entre los grados de los sinónimos implicados en el razonamiento?

### IV. ANÁLISIS EMPÍRICO DEL PROBLEMA

El experimento antes mencionado tiene como finalidad estudiar, a partir de la aproximación gradual al problema de la vaguedad, un método con el cual introducir juicios coherentes no precisos de razonamientos vagos en un sistema automático no supervisado. Más concretamente, el experimento explora la posible correlación existente entre la evaluación lingüística de la conclusión de un razonamiento básico y la separación existente entre los adjetivos valorativos implicados dentro de una escala. El objetivo no es tanto establecer una prueba indiscutible sobre la validez de la aproximación gradual como servir de argumento a favor de una teoría de la vaguedad empírica, la cual podría ser sistematizada sin necesidad de aplicar un método numérico.

#### IV-A. Metodología

El estudio se ha realizado mediante un formulario sobre el que se ha consultado a estudiantes, profesores e investigadores pertenecientes al ámbito universitario. En total, los resultados aquí mostrados se corresponden a las respuestas dadas por 38 participantes. En una primera parte se les hizo una serie de preguntas básicas, a saber: su edad, nivel de estudios y nivel de conocimiento del castellano. Como resultado, la edad media de los participantes ha sido de 25,2 años, y dado que todos han señalado el castellano como su lengua madre (o, en su defecto, un avanzado conocimiento de dicho idioma), y no se han detectado irregularidades en la totalidad de sus respuestas, no ha sido necesario excluir ninguno de los cuestionarios recibidos.

#### IV-B. Materiales y procedimiento

Los adjetivos utilizados para este experimento han sido cuatro, dos asociados a un parámetro medible (edad para “anciano”, temperatura para “caliente”) y dos asociados a uno que no puede ser medido (al menos de manera numérica), siendo “guapo” y “divertido” los elegidos para este último caso<sup>1</sup>.

El cuestionario se divide en dos partes bien diferenciadas. En la primera, al participante se le presentaron 12 textos breves ordenados al azar, cada uno de los cuales se correspondía con una serie de premisas, enriquecidas de forma escueta para proveerles de un contexto que facilitara su comprensión. A continuación se les mostraba una conclusión posible para cada fragmento, y finalmente se les pedía que estableciesen su grado de conformidad con dicha conclusión en una escala Likert<sup>2</sup> de siete puntos [14].

Un ejemplo es el siguiente:

**TEXTO:** “El director de casting de una película pone en varias páginas web el siguiente anuncio: “se necesita actor maduro para una nueva campaña de perfumes”. Al día siguiente su asistente llega a su despacho y le dice que hay un candidato esperando en la sala. Cuando el director le pregunta sobre el aspecto de dicho candidato, el ayudante le dice que es un anciano.”

**PREGUNTA:** “¿Estás de acuerdo con la afirmación “el candidato cumple con los requisitos del anuncio?””

**OPCIONES:** 1) Totalmente de acuerdo, 2) Bastante de acuerdo, 3) Algo de acuerdo, 4) Ni de acuerdo ni en desacuerdo, 5) Algo en desacuerdo, 6) Bastante en desacuerdo, 7) Totalmente en desacuerdo.

La peculiaridad de las premisas aquí presentes es que el punto de unión entre ellas no viene dado por una misma palabra, sino por dos sinónimos, uno de los cuales es siempre uno de los cuatro adjetivos-base antes mencionados (“anciano”, “caliente”, etc.) y el otro uno de sus sinónimos.

Fundamentándonos en la clasificación dada por Cruse [2], Palmer [16] y Lyons [15], existirían tres tipos de sinónimos básicos: sinónimos absolutos (palabras con idéntico significado, como son “computadora” y ordenador” donde la definición de ambas viene sustentada por las mismas acepciones), sinónimos cognitivos (palabras que, a pesar de tener un contenido semántico formal o “intelectual” idéntico, se diferencian en la intención, actitud o carga emotiva de cada una, como son “delgado” y “flaco”, donde “delgado” tiene una carga neutra mientras “flaco” suele utilizarse en sentido peyorativo) y “plesiónimos” o cuasi-sinónimos (palabras entre las que existe una diferencia semántica tal que si una fuera sustituida por otra en una proposición, las condiciones de verdad de dicha proposición cambiarían, como es el caso de “amplio” y “vasto”

<sup>1</sup>La categoría gramatical de los adjetivos ha sido la elegida para el estudio porque a) en la mayoría de los casos son los adjetivos quienes, junto a los adverbios, introducen la vaguedad en nuestro lenguaje, y b) “la gramática tradicional ha reconocido el grado como uno de los accidentes gramaticales del adjetivo”, ya que “expresan propiedades, características o dimensiones que, sin variar de manera cualitativa, puede, en cambio, variar cuantitativamente” [20:6-8].

<sup>2</sup>Una escala Likert es una escala psicométrica utilizada en cuestionarios donde al participante se le presenta una serie de afirmaciones y este debe elegir aquellas opciones que mejor representen su nivel de acuerdo o desacuerdo en cada una. Nos hemos decantado por este tipo de cuestionarios gracias al paralelismo existente entre las escalas Likert (cuyos grados están expresados en lenguaje natural) y las escalas lingüísticas de la segunda parte del experimento.

donde, aunque ambos sirven para designar un espacio grande, “vasto” hace referencia a un espacio mayor que “amplio”).

El cuestionario pretende estudiar la relación de cada uno de los cuatro adjetivos-base con un sinónimo cognitivo y dos cuasi-sinónimos, todos ellos recogidos en WordNet [5] (ver Tabla I)<sup>3</sup>.

Tabla I: Clasificación semántica de los adjetivos utilizados

	Sin. Cognitivo	Cuasi-sinónimo 1	Cuasi-sinónimo 2
Anciano	Viejo	Senil	Maduro
Caliente	Cálido	Ardiente	Tibio
Guapo	Bonito	Precioso	Agraciado
Divertido	Entretenido	Alegre	Animado

La segunda y tercera columna de cuasi-sinónimos se corresponden con los adjetivos que hacen referencia a un grado superior e inferior, respectivamente, de la dimensión a la que están asociados (la temperatura a la que hace referencia “ardiente” es superior a la que hace referencia “caliente”, mientras que la temperatura a la que hace referencia “tibio” es inferior a la que hace referencia “caliente”, etc.). Estos adjetivos han sido elegidos con el fin de que todas las categorías sinonímicas existentes estuviesen representadas en el estudio (cognitivos y cuasi-sinónimos tanto en un grado superior como inferior), así como dos ejemplos claros de adjetivos asociados a medidas (la edad de un “anciano” puede medirse en años, y la temperatura de algo “caliente” en grados centígrados) y otros dos que no pueden ser reducidos a una sola medida (no existe ninguna unidad capaz de indicar de manera explícita el nivel de belleza y/o de diversión).

La segunda parte del cuestionario consiste en darle al participante un conjunto de palabras ordenadas al azar y pedirle que las coloque en una escala de diez posiciones en los lugares que considerase más correctos (el número de posiciones ha sido elegido con el fin de que existiera espacio suficiente para que cada participante situase la distancia que considerase oportuna entre cada par de palabras sin que el tamaño de la escala influyese en su decisión). Cada conjunto se corresponde a uno de los adjetivos-base, sus tres sinónimos utilizados en la primera parte (tal y como aparecen en la Tabla I) y uno o dos sinónimos nuevos más (ver Tabla II).

Por último, a los participantes se les pregunta si alguno de los cuatro conjuntos de palabras les ha resultado especialmente difícil de ordenar.

Tabla II: Grupos de adjetivos

Edad	maduro, envejecido, canoso, senil, viejo, anciano
Temperatura	tibio, ardiente, cálido, templado, caliente
Belleza	guapo, precioso, bonito, cautivador, agraciado, atractivo
Diversión	divertido, alegre, animado, entretenido, ameno

#### IV-C. Predicciones y resultados

El cuestionario fue desarrollado para comprobar si los razonamientos lingüísticos que realizarán los participantes en

<sup>3</sup>La ausencia de sinónimos absolutos en el estudio se debe a que su existencia no es del todo clara, y el número de casos en el que puede sugerirse su existencia dentro de la categoría de los adjetivos es mínimo [2].



la primera parte tienen algún tipo de correlación con su ordenamiento en las escalas de la segunda parte. De ser así, los resultados darían una pista sobre cómo debería implementarse un razonador lingüístico que tuviese en cuenta el contenido semántico vago de los términos en un lenguaje de programación lógica (como veremos a continuación).

Los resultados de la primera parte arrojaron luz sobre el primer punto a tener en cuenta: que las respuestas no están uniformemente distribuidas entre los siete puntos de la escala Likert, sino que se agrupaban en torno a un valor central, formando una curva de tipo distribución normal o Campana de Gauss (ver Fig. 1)<sup>4</sup>. Esto parece indicar que el uso de

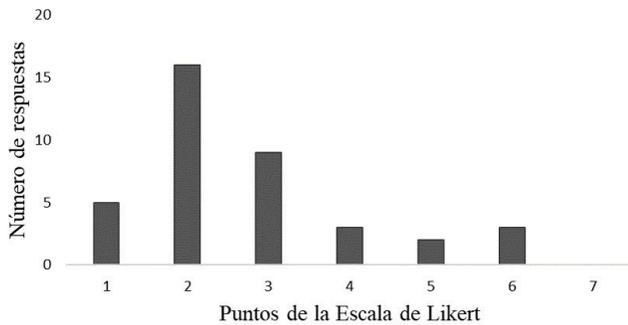


Fig. 1: Distribución de las respuestas para el caso de los sinónimos “anciano” y “senil” en una escala Likert de siete puntos.

sinónimos en un silogismo sí modifica las condiciones de verdad del razonamiento, comportamiento del que no puede dar cuenta un tratamiento de la vaguedad bivalente.

El segundo punto a comentar es que, efectivamente, tal y como se había predicho, las palabras asociadas a una magnitud numérica (edad, temperatura) resultaron más fáciles de ordenar que las asociadas a una magnitud no numérica (belleza, diversión). Esto debe tenerse en cuenta, pues puede ser, a su vez, otra razón que explique por qué las condiciones de verdad de una conclusión se ven modificadas.

Por último, el resultado más relevante de todos puede verse referido en la Fig. 2. El eje de las abscisas está formado por los siete puntos de la escala Likert de la primera parte (igual que en la Fig. 1), y el eje de las ordenadas por un valor numérico entre 0 y 5 que señala la distancia existente entre un par de palabras situadas en la misma escala de la segunda parte (0 = situados en la misma posición, 1 = situados en una posición adyacente, 2 = situados en la escala con una posición de diferencia, etc.). A su vez, cada uno de los doce puntos se corresponde a los doce pares de palabras estudiados en el cuestionario, cuyas coordenadas x-y han sido obtenida

<sup>4</sup>El eje de las abscisas va de 1 a 7, valores numéricos que se corresponden a los siete puntos Likert de la escala:

- 1 = “Totalmente de acuerdo”
- 2 = “Bastante de acuerdo”
- 3 = “Algo de acuerdo”
- 4 = “Ni de acuerdo ni en desacuerdo”
- 5 = “Algo en desacuerdo”
- 6 = “Bastante en desacuerdo”
- 7 = “Totalmente en desacuerdo”

mediante los valores medios de los resultados obtenidos en la primera y segunda parte, respectivamente. Las barras de error están representadas a partir de los valores de la segunda y cuarta columna de la Tabla III y representan sus intervalos de confianza (para un valor de confianza del 95 %). Teniendo

Tabla III: Valores representados en la Fig. 2

Par de palabras	Valor_P1	Conf_P1	Valor_P2	Conf_P2
Anciano-Senil	2.74	0.46	1.58	0.42
Anciano-Viejo	18.7	0.40	1.05	0.30
Anciano-Maduro	5.76	0.44	4.45	0.55
Caliente-Tibio	6.34	0.18	4.21	0.51
Caliente-Cálido	2.82	0.60	1.32	0.28
Caliente-Ardiente	6.05	0.52	2.24	0.34
Guapo-Bonito	2.37	0.47	1.47	0.36
Guapo-Agraciado	3.34	0.49	2.34	0.47
Guapo-Precioso	4.42	0.65	2.26	0.39
Divertido-Entretenido	4.55	0.57	2.79	0.59
Divertido-Animado	3.13	0.50	2.34	0.45
Divertido-Alegre	3.68	0.47	2.08	0.45

todos estos valores en consideración, la recta representada en la gráfica es una estimación obtenida mediante la técnica de mínimos cuadrados con un coeficiente de determinación o  $R^2$  de 0,70, valor que refleja la muy buena calidad de este ajuste.

## V. CONCLUSIÓN Y DISCUSIÓN GENERAL

Los resultados antes expuestos nos permiten concluir dos hechos relevantes, siendo el primero que la sustitución de una palabra  $A$  por un sinónimo  $SinA$  en un razonamiento natural casi siempre se percibe como una pérdida de las condiciones de verdad de la conclusión (de no ser así, todas o casi todas las respuestas se corresponderían al primer punto de la escala Likert). En segundo lugar, nos ha permitido comprobar que, si la palabra sustituida  $A$  dentro del razonamiento es un sinónimo valorativo graduable, la modificación de las condiciones de verdad percibida por un ser humano se relaciona directamente con la separación existente entre los grados representados por  $A$  y  $SinA$  dentro de una escala lingüística obtenida de manera empírica.

Si las implicaciones de nuestro experimento resultan correctas, en estos casos ya no sería necesario reducir el contenido semántico de una palabra a valores numéricos mediante la

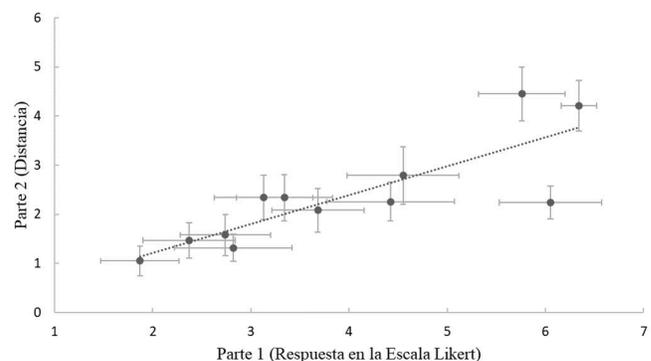


Fig. 2: Representación de los datos del estudio (Tabla III) y su ajuste por mínimos cuadrados.

lógica difusa para su tratamiento no supervisado. Entonces un lenguaje de programación lógica como Prolog podría arrojar más soluciones que las aportadas actualmente, valorando el grado de verdad de cada conclusión de manera lingüística midiendo únicamente la distancia entre los grados asociados a cada término dentro de una escala.

Por supuesto, quedan por resolver algunas cuestiones antes de considerar plausible esta solución, siendo el problema más relevante el de la desambiguación de los términos implicados en un silogismo. Aun limitándonos a tratar únicamente el significado cognitivo (o puramente lógico) de los términos, todavía quedaría determinar la dimensión o magnitud a la que están haciendo referencia en el razonamiento. Y es que, por ejemplo, no es lo mismo utilizar el adjetivo “senil” para hacer referencia a la avanzada edad de un ser humano que a su deterioro cognitivo, ya que en ambos contextos el adjetivo hará referencia a dos grados diferentes, cada uno perteneciente a su propia escala.

Con lo que respecta a los datos tomados, la estimación por mínimos cuadrados nos muestra de manera bastante precisa que cada punto de la escala Likert de la primera parte encuentra una correspondencia directa con una de las distancias establecidas por los participantes en la segunda parte. Si el objetivo es diseñar un método resolutivo que emule la manera de juzgar una conclusión de los seres humanos, de acuerdo a lo aquí expuesto la información podría quedar recogida en escalas ordenadas de manera empírica por el suficiente número de usuarios, lo que simplificaría las inferencias aproximadas o vagas realizadas al estilo Prolog. Por ejemplo, en el caso de un razonamiento tipo Prolog, bastaría con modificar el proceso de unificación con una nueva regla según la cual el emparejamiento entre dos términos se produciría también si los grados asociados a ambos términos en el contexto dado pertenecen a la misma escala, añadiendo en esos casos un determinado “grado de coherencia” al emparejamiento por medio de la distancia existente entre ambos grados.

Para concluir es importante señalar que, aunque es sorprendente la precisión con la que los datos señalan una correlación entre las distancias que existen entre grados y juicios valorativos, los resultados en sí no lo son. Al fin y al cabo, si aceptamos la premisa principal de la aproximación gradual según la cual el contenido semántico cognitivo de los adjetivos se expresa mediante los grados a los que estos hacen referencia, es evidente que cuanto más alejados estén los grados de  $A$  y  $\text{Sin}A$  dentro de una misma escala, mayores serán los cambios introducidos en las condiciones de verdad de la conclusión del silogismo al sustituir un término medio por otro.

En todo lo discutido anteriormente, hay que tener en cuenta que para comprobar la validez de estos resultados sería necesario repetir el experimento para un número mayor de participantes y palabras. De igual forma, en futuros estudios cabría la posibilidad de estudiar si este tratamiento de la vaguedad puede extenderse a otras categorías gramaticales sensibles de poseer un contenido semántico vago (tales como los adverbios o, en cierta medida, los sustantivos o incluso los

verbos) o si, por el contrario, requieren de un enfoque distinto, no fundamentado en el uso de escalas y grados.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía y Competitividad (proyectos TIN2014-56633-C3-1-R y TIN2017-84796-C2-1-R) y la Consellería de Educación de la Xunta de Galicia (proyectos GRC2014/030 y Acreditación 2016-2019, ED431G/08”). Todos los proyectos fueron cofinanciados por el programa FEDER.

#### REFERENCIAS

- [1] L. C. Burns, “Vagueness: an investigation into natural languages and the Sorites paradox”, *Philosophy and Phenomenological Research* 54(2), 1994, pp. 483-486.
- [2] D. A. Cruse, *Lexical Semantics*. Cambridge University Press, 1986.
- [3] M. Dummett, “Wang’s paradox”, *Synthese*, 30, 1975, pp. 301-24.
- [4] D. Edgington, *Vagueness by Degrees*. In Rosanna Keefe and Peter Smith (eds.), *Vagueness: A Reader*. MIT Press, 1997.
- [5] C. Fellbaum, *WordNet. An Electronic Lexical Database*. Cambridge, MA: MIT Press, 1998. Disponible en: <http://wordnetweb.princeton.edu/perl/webwn>. [Consulta: 16 junio 2018].
- [6] K. Fine, “Vagueness, truth and logic”, *Synthese* 30(3-4), 1975, pp.265-300.
- [7] M. Ishizuka, y N. Kanai, “Prolog-ELF incorporating fuzzy logic”, *New Generation Computing*, 3(4),1985, pp.479-486.
- [8] C. Kennedy, *Projecting the adjective: The syntax and semantics of gradability and comparison*. New York: Garland, 1999.
- [9] C. Kennedy, “Polar opposition and the ontology of ‘degrees’”. *Linguistics and Philosophy*, 24, 2001, pp. 33-70.
- [10] C. Kennedy, y L. McNally, “Scale structure and the semantic typology of gradable predicates”. *Language*, 81(2), 2005, pp. 345-381.
- [11] R. C. T. Lee, “Fuzzy logic and the Resolution Principle”. *Journal of the Association for Computing Machinery*, 19(1), 1972, pp. 109-119.
- [12] S. C. Levinson, *Pragmática*. Barcelona: Teide, 1989.
- [13] D. Li, and D. Liu, *A Fuzzy Prolog Database System*. Research Studies Press and John Wiley and Sons, 1990.
- [14] R. Likert, “A technique for the measurement of attitudes”. *Archives of Psychology*, 140, 1932, pp. 1-55.
- [15] J. Lyons, *Introduction to Theoretical Linguistics*. Cambridge University Press, 1968.
- [16] F. R. Palmer, *Semantics: A new outline*. Cambridge University Press, 1976.
- [17] M. Pereira-Fariña, A. Sobrino, and A. Bugarín, “A proposal of fuzzy chained syllogism based on the concept of synonymy”. *Fuzzy Systems (FUZZ-IEEE)*, 2013, pp. 1-8.
- [18] W. V. Quine, “What price bivalence?”, *Journal of Philosophy* 78 (2), 1981, pp. 90-95.
- [19] B. Russell, “Vagueness”. *Australasian Journal of Philosophy* 1 (2), 1923, pp. 84-92.
- [20] C. Sánchez López, *El grado de adjetivos y adverbios*. Madrid: Arco/Libros, 2006.
- [21] D. H. Sanford, “Competing semantics of vagueness: Many values versus super-truth”. *Synthese* 33 (2-4), 1976, pp. 195-210.
- [22] A. Sobrino, “The Role of Synonymy and Antonymy in Natural Fuzzy Prolog”. *Soft Computing in Humanities and Social Sciences*. R. Seising, V. Sanz (eds.), Springer Berlin Heidelberg, 2012, pp. 209-236.
- [23] L. Wittgenstein, *Philosophical Investigations*, trad. Anscombe, G.E.M. Wiley-Blackwell, 1953.
- [24] C. Wright, “On the coherence of vague predicates”, *Synthese* 30 (3-4), 1975, pp. 325-65.
- [25] L.A. Zadeh, “Fuzzy logic = computing with words”. *IEEE Transactions of Fuzzy Systems*, 4(2), 1996, pp. 103-111.
- [26] L.A. Zadeh, “From computing with numbers to computing with words: From manipulation of measurements to manipulation of perceptions”. *Circuits and Systems I: Fundamental Theory and Applications*, IEEE, 46(1), 1999, pp. 105-119.



# Uso de Expresiones Lingüísticas Comparativas en AFRYCA 3.0

1º Álvaro Labella  
Dpto. de Informática  
Universidad de Jaén  
Jaén, España  
alabella@ujaen.es

2º Rosa M. Rodríguez  
Dpto. de CC de la Computación e IA  
Universidad de Granada  
Granada, España  
rosam.rodriguez@decsai.ugr.es

3º Luis Martínez  
Dpto. de Informática  
Universidad de Jaén  
Jaén, España  
martin@ujaen.es

**Resumen**—La mayor parte de los problemas de Toma de Decisión en Grupo (TDG) del mundo real se definen en contextos de incertidumbre, en los cuales hay que modelar y operar con información vaga e imprecisa. El uso Enfoque Lingüístico Difuso ha proporcionado excelentes resultados en el tratamiento de dicha incertidumbre. Sin embargo, dicho enfoque presenta limitaciones en la expresión de la información debido al uso de vocabularios limitados y cerrados, lo que demanda expresiones lingüísticas más flexibles y no limitadas a priori. Para ello, se introdujo el concepto de *Conjunto de Términos Lingüísticos Difusos Dudosos* (CTLDD) que permite modelar Expresiones Lingüísticas Comparativas (ELCs). En los problemas de TDG, los Procesos de Alcance de Consenso (PAC) son uno de los principales campos de investigación, dando lugar a numerosas propuestas de PAC. Como consecuencia, la labor de seleccionar y aplicar el PAC más adecuado para un problema de TDG dado puede resultar compleja. Por esta razón se diseñó AFRYCA, un framework para el estudio y análisis de problemas de TDG. Esta contribución presenta nuevas características de la versión 3.0 de AFRYCA para el modelado de incertidumbre mediante información lingüística difusa dudosa y ELCs en PAC.

**Palabras clave**—AFRYCA, toma de decisión en grupo, consenso, expresiones lingüísticas comparativas

## I. INTRODUCCIÓN

La Toma de Decisiones (TD) es habitual en nuestras actividades diarias en las que, a partir de un conjunto de posibles opciones o alternativas, se debe escoger la mejor. En la Toma de Decisión en Grupo (TDG), un grupo de expertos son los encargados de decidir cuál es la mejor solución para un problema de TD [4], [8]. Los problemas de TDG normalmente se definen en contextos bajo incertidumbre donde la información es vaga e imprecisa. Existen diferentes enfoques que manejan este tipo de información [20]–[22], entre ellos, el *Enfoque Lingüístico Difuso* [22] ha proporcionado buenos resultados en la resolución de problemas de TDG definidos bajo incertidumbre. Hasta ahora estos enfoques modelaban la información lingüística utilizando un único termino lingüístico, lo que limita la expresión del conocimiento de los expertos [14]. Varias propuestas se han presentado en la literatura para intentar superar esta limitación y permitir utilizar más de un término lingüístico. En esta contribución se introduce el concepto de *Conjunto de Términos Lingüísticos Difusos Dudosos*

(CTLDD) [15]. Un CTLDD permite modelar la información lingüística mediante el uso de varios términos lingüísticos, permitiendo a los expertos expresar la duda entre ellos. Las *Expresiones Lingüísticas Comparativas* (ELCs) hacen uso de los CTLDDs y permiten a los expertos expresar sus opiniones de una forma más cercana a su modelo cognitivo habitual.

Las necesidades en la resolución de los problemas de TDG han evolucionado a lo largo del tiempo. En ocasiones, ya no solo se requiere encontrar la mejor solución, sino que además, esa solución debe de ser satisfactoria para todo el grupo. Tradicionalmente, los problemas de TDG se resolvían aplicando un proceso de selección de alternativas [2], donde se tenían en cuenta las opiniones individuales de los expertos, pero no el acuerdo entre ellos [16]. Por lo tanto, la decisión final podía no ser del agrado de todos los expertos, provocando que parte de ellos se sintieran excluidos del proceso de decisión. Por esta razón surgieron los Procesos de Alcance de Consenso (PAC) como una fase adicional en la resolución de problemas de TDG [17]. En un PAC, los expertos revisan, discuten y modifican sus opiniones con el objetivo de alcanzar una solución que satisfaga al grupo. Los PAC se han convertido en un pilar fundamental dentro del marco de la TDG y, como consecuencia, se pueden encontrar numerosas propuestas de modelos de PAC, también denominados *modelos de consenso* [1], [3], [5]. Debido a esto, identificar y aplicar el modelo de consenso que mejor se adapte a un problema de TDG puede resultar una tarea ardua, compleja y que demanda mucho tiempo.

AFRYCA, *A FRamework for the analySis of Consensus Approaches*, es un framework que permite el análisis y estudio de la resolución de problemas de TDG mediante la simulación de PAC [10]. Los principales objetivos de AFRYCA son: identificar ventajas y desventajas de los diferentes modelos de consenso, establecer comparaciones entre modelos de consenso, identificar cuándo un modelo de consenso es más apropiado para un problema de TDG en particular y visualizar la evolución de las preferencias de los expertos a lo largo del PAC. AFRYCA permite llevar a cabo estas tareas mediante la simulación de PAC, lo que conlleva simular los comportamientos de los expertos que participan en el proceso. Desde su inicio, AFRYCA ha evolucionado tanto en tecnologías como en herramientas para PAC [7]. En esta

Esta contribución está parcialmente financiada por el proyecto de investigación TIN2015-66524-P.

contribución se presenta una nueva versión de AFRYCA que incluye nuevas capacidades para el tratamiento de información lingüística difusa dudosa. Estas funcionalidades son: definición de problemas de TDG donde los expertos expresan sus preferencias mediante el uso de ELCs, soporte para la visualización de dichas preferencias e incorporación de un nuevo modelo de consenso para este tipo de información.

Esta contribución se estructura de la siguiente forma: en la Sección II se introducen brevemente algunos conceptos preliminares. En la Sección III se presenta AFRYCA 3.0 y sus nuevas funcionalidades, mientras que en la Sección IV se muestra un ejemplo ilustrativo de dichas funcionalidades. Finalmente, la Sección V expone algunas conclusiones y trabajos futuros.

## II. PRELIMINARES

Aquí se revisan distintos conceptos necesarios para entender AFRYCA y el uso de CTLDDs en dicho framework.

### II-A. Toma de Decisión en Grupo

Un problema de TDG está compuesto por un conjunto de expertos,  $E = \{e_1, e_2, \dots, e_m\}$ , que opinan sobre un conjunto de alternativas  $X = \{x_1, x_2, \dots, x_n\}$  evaluadas en base a un conjunto de criterios  $C = \{c_1, c_2, \dots, c_k\}$ , con el objetivo de encontrar la mejor solución [8]. Es habitual que las opiniones de los expertos sobre las alternativas se representen mediante relaciones de preferencia. Una relación de preferencia asociada con el experto  $e_i$  se nota como  $P_i = (p_i^{lk})_{n \times m}$  y se representa en (1) tal que:

$$P_i = \begin{pmatrix} - & \dots & p_i^{ln} \\ \vdots & \ddots & \vdots \\ p_i^{n1} & \dots & - \end{pmatrix} \quad (1)$$

Existen distintos tipos relaciones de preferencia según la información que utilicen, las más comunes son:

- *Relación de preferencia difusa* [9]: En una Relación de Preferencia Difusa (RPD), cada valoración  $p_i^{lj} = \mu_{P_i}(x_l, x_j) \in [0, 1]$  representa el grado de preferencia de  $e_i$  sobre  $x_l$  con respecto a  $x_j$ ,  $l, k \in \{1, \dots, n\}, l \neq j$ .
- *Relación de preferencia lingüística* [11]: En una Relación de Preferencia Lingüística (RPL), cada valoración  $p_i^{lj} \subseteq X \times X$ , con un grado de preferencia  $\mu_p : X \times X \rightarrow S$ , donde  $S$  es un conjunto de etiquetas predefinido y  $\mu_p(x_l, x_j) = p_{lj}$  representa el grado de preferencia lingüístico de la alternativa  $x_l$  sobre  $x_j$ .
- *Relación de preferencia dudosa* [19]: En una Relación de Preferencia Dudosa (RPDD), cada valoración  $p_i^{lj} \subseteq X \times X$ , donde  $p_{lj} = \{p_{lj}^\beta, \beta = 1, 2, \dots, \#p_{lj}\}$  ( $\#p_{lj}$  es el número de valores en  $p_{lj}$ ), es un elemento difuso dudoso que indica todos los posibles grados de preferencia de la alternativa  $x_l$  sobre  $x_j$ .
- *Relación de preferencia lingüística dudosa* [13], [14]: En una Relación de Preferencia Lingüística Dudosa (RPLD), cada valoración  $p_i^{lj} \subseteq X \times X \rightarrow S$ , donde  $S$  es un conjunto de etiquetas predefinido y  $p_{lj} =$

$\{p_{lj}^\beta \mid \beta = 1, 2, \dots, \#p_{lj}\}$  ( $\#p_{lj}$  es el número de términos lingüísticos en  $p_{lj}$ ), es un conjunto de términos lingüísticos difusos que indica todos los posibles grados de preferencia de la alternativa  $x_l$  sobre  $x_j$ .

### II-B. Procesos de Alcance de Consenso

Los PAC son procesos iterativos y dinámicos, en los que los expertos modifican sus opiniones iniciales con el objetivo de acercar posturas y alcanzar un alto nivel de acuerdo sobre las preferencias del problema de TDG después de varias rondas de debate [17]. Un PAC es normalmente guiado por un *moderador* que supervisa el proceso. En problemas de TDG bajo incertidumbre, la lógica difusa desempeña un papel importante al proporcionar modelos de representación y procesamiento de información en opiniones vagas e imprecisas.

Los PAC se incluyen como una fase adicional dentro del esquema de resolución de problemas de TDG, con el objetivo de obtener una solución consensuada que satisfaga a los expertos involucrados en la toma de decisiones. El concepto de *consenso* ha sido definido desde diferentes puntos de vista: (i) A veces como la *unanimidad*, aunque esta visión es poco realista y prácticamente imposible de alcanzar en problemas de TDG reales. (ii) Otras veces se han aportado visiones más flexibles, como la de *soft consensus* o *consenso suave*, basada en el concepto de mayoría difusa definida por Kacprzyk [4], más cercana a la percepción que el ser humano tiene del consenso. Según este concepto, el consenso es alcanzado cuando *la mayoría de los individuos están de acuerdo en la mayoría de las cuestiones más relevantes*.

Las fases que componen un PAC son:

1. *Recolección de preferencias*: Se recoge la opinión de cada experto sobre las alternativas.
2. *Cálculo del nivel de consenso*: Se calcula el nivel de consenso alcanzado por el grupo en la ronda de consenso.
3. *Control de consenso*: Se compara el nivel de consenso obtenido con un valor umbral predefinido que representa el mínimo nivel de consenso que debe de ser alcanzado en el PAC. Si el nivel de consenso alcanzado por el grupo es mayor que el umbral, se inicia el proceso de selección de la mejor alternativa, en caso contrario se iniciará una nueva ronda de consenso.
4. *Generación de recomendaciones*: Cuando no se alcanza el umbral de consenso, es necesario iniciar un proceso en el cual las opiniones de los expertos deben modificarse para así acercar posturas entre ellos. Este proceso será llevado a cabo por el moderador [10], que debe proporcionar sugerencias a los expertos involucrados para que modifiquen sus opiniones iniciales.

### II-C. Conjuntos de Términos Lingüísticos Difusos Dudosos

El concepto de CTLDD se introdujo para facilitar la labor de los expertos a la hora de dar sus valoraciones empleando expresiones lingüísticas, especialmente en aquellos casos en los que dudan entre varios términos lingüísticos.



**Definición 1:** [15] Sea  $S = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos, un CTLDD,  $H_S$ , se define como un subconjunto finito ordenado de términos lingüísticos consecutivos de  $S$ .

$$H_S = \{s_i, s_{i+1}, \dots, s_j\}, \text{ tal que, } s_k \in S, k \in \{i, \dots, j\} \quad (2)$$

El concepto de CTLDD facilita el modelado de las opiniones de los expertos mediante múltiples términos lingüísticos, sin embargo, no es parecida a cómo los seres humanos expresan sus opiniones. Por esta razón, se presentaron las ELCs [15], dichas expresiones se generan mediante una gramática libre de contexto y son próximas, en términos de expresividad, a la forma de expresarse de los seres humanos.

**Definición 2:** [15] Sea  $G_H$  una gramática libre de contexto y  $S = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos. Los elementos de  $G_H = (V_N, V_T, I, P)$  son definidos como:

$$\begin{aligned} V_N &= \{(\text{término primario}), (\text{término compuesto}), \\ &(\text{relación unaria}), (\text{relación binaria}), \\ &(\text{conjunción})\} \\ V_T &= \{\text{menor que}, \text{mayor que}, \text{entre}, \text{y}, s_0, s_1, \dots, s_g\} \\ I &\in V_N \end{aligned}$$

Las reglas de producción son definidas mediante la forma extendida de Backus Naur, en la que la utilización de paréntesis indica elementos opcionales y el símbolo  $|$  indica elementos alternativos.

$$\begin{aligned} P &= \{I ::= (\text{término primario})|(\text{término compuesto}) \\ &(\text{término compuesto}) ::= (\text{relación unaria}) \\ &(\text{término primario})|(\text{relación binaria})|(\text{término primario}) \\ &(\text{conjunción})|(\text{término primario}) \\ &(\text{término primario}) ::= s_0|s_1|\dots|s_g \\ &(\text{relación unaria}) ::= \text{menor que}| \text{mayor que} \\ &(\text{relación binaria}) ::= \text{entre} \\ &(\text{conjunción}) ::= \text{y}\} \end{aligned}$$

Dichas expresiones lingüísticas comparativas pueden ser representadas mediante CTLDD utilizando la función  $E_{G_H}$ .

**Definición 3:** [15] Sea  $E_{G_H}$  una función de transformación entre expresiones lingüísticas  $ll$ ,  $ll \in G_H$ , y  $H_s$ , siendo  $S$  el conjunto de términos lingüísticos utilizados por  $G_H$ :

$$E_{G_H} : ll \rightarrow H_S$$

Dependiendo del tipo de ELC, su transformación en CTLDD se lleva a cabo de diferentes formas:

- $E_{G_H}(s_i) = \{s_i/s_i \in S\}$
- $E_{G_H}(\text{menor que } s_i) = \{s_j/s_j \in S \text{ y } s_j \leq s_i\}$
- $E_{G_H}(\text{mayor que } s_i) = \{s_i/s_i \in S \text{ y } s_j \geq s_i\}$
- $E_{G_H}(\text{entre } s_i \text{ y } s_j) = \{s_i/s_i \in S \text{ y } s_i \leq s_k \leq s_j\}$

### III. EXPRESIONES LINGÜÍSTICAS COMPARATIVAS EN AFRYCA 3.0

En esta sección se muestran las nuevas funcionalidades de la versión 3.0 de AFRYCA relacionadas con el modelado de información lingüística difusa dudosa mediante ELCs. Primero se presenta la arquitectura software de AFRYCA 3.0, y después el esquema de resolución del framework. Por último, se analizan las nuevas funcionalidades en detalle.

#### III-A. Arquitectura de AFRYCA 3.0

AFRYCA es una aplicación software desarrollada bajo la plataforma *Eclipse Rich Client Platform* (RCP), una plataforma para construir y desarrollar aplicaciones multiplataforma ricas de escritorio fáciles de mantener y extender. Estas características vienen determinadas por el tipo de arquitectura software sobre la que se construye el framework. Dicha arquitectura *basada en componentes* está diseñada para resolver los problemas más comunes en el desarrollo software, como son el mantenimiento, reutilización, ampliación y modificación. Los componentes, también denominados *plug-ins*, son pequeñas porciones de software que se conectan entre si formando una aplicación software.

Anteriores versiones de AFRYCA se desarrollaron empleando la rama estable de Eclipse RCP, 3.X. El uso de esta rama proporcionaba ciertas ventajas, como una mayor estabilidad, documentación y compatibilidad con componentes de terceros. Sin embargo, en términos tecnológicos, AFRYCA no presentaba ninguna evolución. Este es el motivo por el que AFRYCA 3.0 ha sido desarrollada bajo la nueva rama 4.X de Eclipse RCP, e4. Esta evolución permite que AFRYCA 3.0 se beneficie de nuevas tecnologías orientadas al desarrollo de aplicaciones bajo una arquitectura basada en componentes como la inyección de dependencias o el uso de servicios declarativos.

AFRYCA 3.0 está compuesta por más de 100 componentes, todos desarrollados bajo la rama 4.X (Fig. 1).

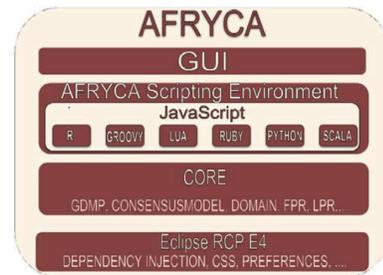


Figura 1. Arquitectura de AFRYCA 3.0

Visitar la web de AFRYCA para más información<sup>1</sup>.

#### III-B. Esquema de Resolución de AFRYCA 3.0

El esquema de resolución de AFRYCA para problemas de TDG se basa en diferentes fases que son descritas a continuación:

<sup>1</sup><http://sinbad2.ujaen.es/afryca/es>

1. *Definición del problema de TDG*: Aquí se define el problema de TDG, incluyendo *expertos*, *alternativas* y *criterios*. Además, también se recogen las opiniones de los expertos, que pueden emplear diferentes tipos de relaciones de preferencia. AFRYCA 3.0 da soporte a RPD, RPL, RPDD y RPLD.
2. *Selección del modelo de consenso*: El siguiente paso es seleccionar el modelo de consenso que se va a emplear en la simulación del PAC. AFRYCA 3.0 tiene incorporados un conjunto de modelos de consenso separados en dos grandes grupos, aquellos que utilizan un proceso de generación de recomendaciones y los que no.
3. *Configuración de los parámetros del modelo de consenso*: Una vez seleccionado el modelo de consenso, es indispensable configurar sus parámetros. Los parámetros de un modelo de consenso influyen directamente en el resultado de la simulación y deben ser ajustados en base al problema de TDG que se esté tratando.
4. *Selección del comportamiento de expertos*: Para llevar a cabo la simulación del PAC, AFRYCA simula el comportamiento de los expertos que participan en el proceso. Actualmente, AFRYCA 3.0 incluye dos tipos de patrones de comportamientos, *estándar* y *estándar con oposición*. En el patrón de comportamiento estándar los expertos pueden *aceptar* o *rechazar* las recomendaciones. En el caso del patrón de comportamiento estándar con oposición; los expertos pueden *aceptar*, *rechazar* o *ir en contra* de las recomendaciones sugeridas.
5. *Configuración de los parámetros del comportamiento*: Al igual que en los modelos de consenso, es posible configurar los parámetros de un patrón de comportamiento. Los patrones de comportamiento se simulan siguiendo una distribución de probabilidad binomial. La configuración de los parámetros de la distribución determinan el comportamiento de los expertos, por ejemplo, definiendo la probabilidad de que un experto acepte una recomendación. Es obvio que la evolución de un PAC será muy distinta si el patrón de comportamiento seleccionado define una probabilidad muy alta de aceptar la recomendación frente a una muy baja.

**Nota:** En el caso de seleccionarse un modelo de consenso que no aplique un proceso de generación de recomendaciones, no es necesario llevar a cabo los dos últimos pasos para comenzar la simulación.

### III-C. Soporte de Información Lingüística Difusa Dudosa en AFRYCA

Posibilitar el modelado de información lingüística dudosa en AFRYCA y el uso de ELCs, ha requerido del desarrollo de nuevos componentes software que han sido incorporados y conectados con el resto de componentes que componen el framework. Estos nuevos componentes han dotado a AFRYCA de nueva funcionalidad que será explicada de forma detallada a continuación.

- *Soporte de conjuntos de términos lingüísticos difusos*: AFRYCA 3.0 permite la creación de conjuntos de térmi-

nos lingüísticos difusos [21]. Los términos lingüísticos de los que se componen el conjunto, son representados mediante etiquetas lingüísticas representadas por funciones de pertenencia triangulares. AFRYCA 3.0 permite la creación de este tipo de conjuntos con cualquier número de etiquetas lingüísticas. Un ejemplo de creación de un conjunto de este tipo se muestra en la Fig. 2.

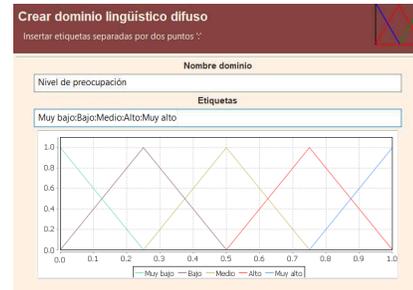


Figura 2. Creación de un conjunto de términos lingüísticos difusos

- *Soporte de relaciones de preferencia lingüísticas dudosas*: AFRYCA modela RPLD cuyos valores están representados por ELCs (ver Fig. 3). Para la generación de las ELCs es indispensable previamente definir un conjunto de términos lingüísticos difusos con el que formar las expresiones. Además, AFRYCA también puede llevar a cabo la transformación de ELCs a CTLDD.



Figura 3. Relación de preferencia lingüística difusa dudosa

- *Modelos difusos de consenso*: La capacidad de tratar información lingüística difusa dudosa en AFRYCA abre un abanico de nuevas posibilidades en cuanto modelos de consenso se refiere. Ahora es posible incluir modelos de consenso que lleven a cabo operaciones con ELCs, lo que permite realizar nuevas comparaciones entre modelos y estudios sobre su funcionamiento. En relación a esto, se ha incorporado un nuevo modelo de consenso [12] que emplea ELCs.
- *Visualización de RPLD*: Una de las principales características de AFRYCA es la visualización de las preferencias de los expertos a los largo del PAC simulado. El incorporar un nuevo tipo de información y por tanto de relación de preferencia, conlleva a incluir nuevas formas de visualización. AFRYCA emplea dos técnicas para visualizar las preferencias de los expertos que son el *escalamiento multidimensional* [6] y la técnica de *análisis*



de componentes principales [18]. Estas dos técnicas han tenido que ser adaptadas para representar la información lingüística difusa dudosa a partir de RPLD.

IV. EJEMPLO ILUSTRATIVO

Con el objetivo de mostrar el funcionamiento de las nuevas funcionalidades de AFRYCA 3.0, relacionadas con la representación y computación de ELCs, esta sección presenta un problema de TDG en el cual los expertos expresan sus opiniones a través de ELCs y que empleará un modelo difuso de consenso orientado a trabajar con ELCs [12].

Spongamos el entrenador de la Selección Nacional de Fútbol que debe realizar la convocatoria de aquellos jugadores que participarán en la Copa del Mundo de 2018 que se celebrará en Rusia. Al ser una decisión tan compleja y delicada, el entrenador no la tomará solo y será aconsejado por sus tres asistentes, tomando la decisión final un total de 4 profesionales,  $E = \{e_1, e_2, e_3, e_4\}$ . Después de disputar todos los partidos de clasificación a la Copa del Mundo el seleccionador y sus asistentes tienen clara la mayor parte de la convocatoria, únicamente queda una plaza vacante que la disputan 4 jugadores,  $A = \{a_1, a_2, a_3, a_4\}$ . De los jugadores únicamente será evaluada su técnica con el balón  $C = \{c_1\}$ . Debido a la complejidad de la decisión y a la duda que genera, el entrenador y sus asistentes proporcionan sus preferencias sobre los jugadores usando RPLD cuyos valoraciones están representadas por ELCs. Los técnicos usarán el conjunto de términos lingüísticos representado en la Fig. 4 para generar las ELCs y valorar la calidad de los futbolistas.

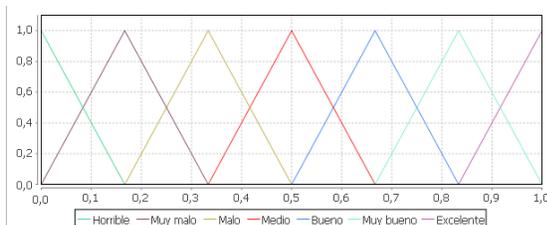


Figura 4. Conjunto de términos lingüísticos

Para resolver de forma consensuada el problema de TDG planteado, seguiremos el esquema de resolución de AFRYCA introducido en la Sección III-B. Se define el problema de TDG junto con todos sus elementos, el conjunto de expertos  $E = \{e_1, e_2, e_3, e_4\}$ , alternativas  $A = \{a_1, a_2, a_3, a_4\}$  y criterios, que en este caso solo es uno que representa la calidad del futbolista  $C = \{c_1\}$ . También se definen las preferencias de los expertos mediante RPLD. La Fig. 5 ilustra la definición del problema empleando AFRYCA.

- *Definición del problema de TDG*
- *Selección del modelo de consenso* Una vez definido el problema, el siguiente paso es seleccionar el modelo de consenso. Para este problema se selecciona el modelo de consenso difuso presentado por Rodríguez et al. [12] (ver Fig 6), centrado en el tratamiento de CTLDDs donde los expertos expresan sus opiniones a partir de ELCs.

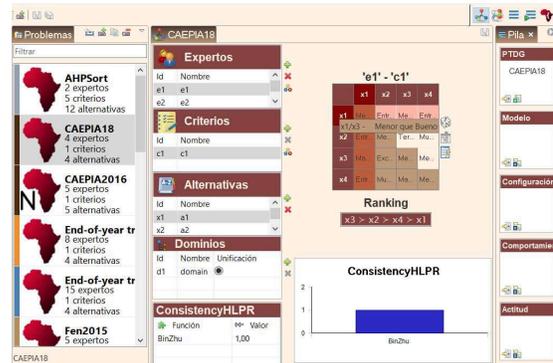


Figura 5. Definición del problema

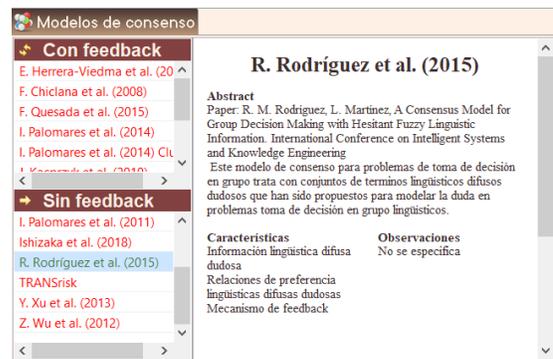


Figura 6. Selección del modelo de consenso

- *Configuración de los parámetros del modelo de consenso* Cuando se selecciona un modelo de consenso, se deben configurar sus parámetros junto con dos adicionales que son incluidos en todos los modelos de consenso, éstos son el umbral de consenso y el máximo número de rondas permitidas en el PAC ( $\mu$  y  $h_{max}$  en Fig. 7). La configuración de los parámetros del modelo seleccionado se representa en la Fig. 7.

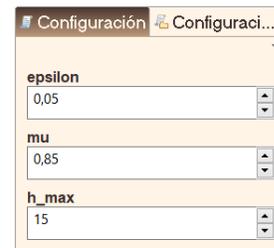


Figura 7. Configuración de parámetros

Ya que el modelo de consenso seleccionado no emplea un mecanismo de generación de recomendaciones, no es necesario llevar a cabo ningún paso más para comenzar con la simulación del PAC y obtener una solución del problema.

Una vez se han completado todos los pasos previamente definidos, se lleva a cabo la simulación del PAC. El resultado

se muestra en la Fig. 8. Además, AFRYCA permite visualizar la evolución de las preferencias de los expertos a lo largo del PAC. Esta visualización, empleando para ello la técnica de escalamiento multidimensional, se muestra en la Fig. 9. Notar que en este tipo de visualización siempre se representa la opinión colectiva del grupo en el centro del eje de coordenadas.

Resultados	
• Consenso alcan...	0,86
• N° de rondas	8
• Ranking	$x_3 > x_4 > x_1 > x_2$
• Conjunto solución	{ $x_3$ }

Figura 8. Resultado de la simulación

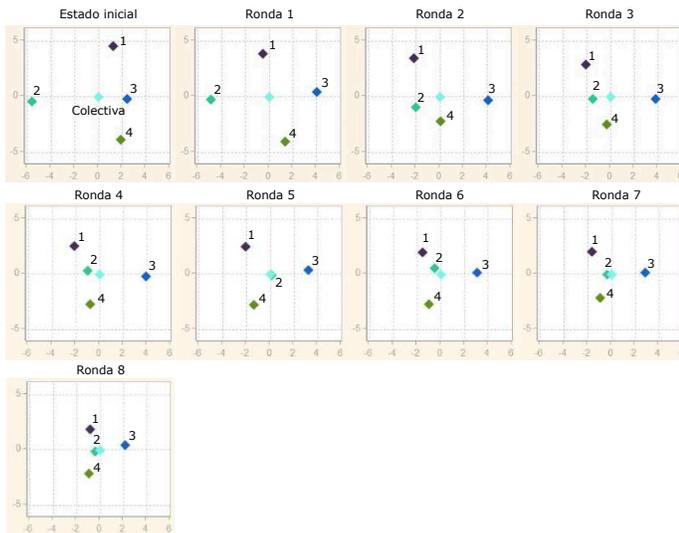


Figura 9. Evolución de las preferencias de los expertos

En la Fig. 8 se muestra que el consenso final alcanzado por los expertos es 0.86, y se han necesitado de un total de 8 rondas para alcanzar el grado de consenso fijado. La Fig. 9 también nos permite ver la evolución de los expertos a lo largo del PAC y como van acercando posturas en las sucesivas rondas de debate. Este acercamiento de posturas puede apreciarse fácilmente, los expertos modifican sus preferencias con el objetivo de llegar a un consenso con el resto del grupo, lo que conlleva a que su opinión esté cada vez más próxima a la opinión colectiva del grupo y su posición en el gráfico tienda hacia el centro. Finalmente, si se aplica un proceso de selección a este consenso, el jugador que debería ser convocado es  $x_3$ .

## V. CONCLUSIONES

AFRYCA es una herramienta software que permite la resolución de problemas de TDG mediante la simulación de PAC, diseñada bajo una arquitectura basada en componentes cuyas principales ventajas son la reusabilidad y la inclusión de nuevas características. En esta contribución se han presentado nuevas funcionalidades de AFRYCA relacionadas con

el manejo de información lingüística difusa dudosa y más concretamente con ELCs. Además se ha descrito tanto la arquitectura como el esquema de resolución del framework. Este conjunto de nuevas funcionalidades abre camino a futuras mejoras en AFRYCA como la inclusión de nuevos modelos difusos de consenso que empleen información lingüística y la incorporación de nuevos tipos de expresiones lingüísticas.

## REFERENCIAS

- [1] S. Alonso, I.J. Pérez, F.J. Cabrerizo, and E. Herrera-Viedma. A linguistic consensus model for web 2.0 communities. *Applied Soft Computing*, 13(1):149–157, 2013.
- [2] F. Herrera, E. Herrera-Viedma, and J.L. Verdegay. A sequential selection process in group decision making with linguistic assessments. *Information Sciences*, 85(4):223–239, 1995.
- [3] E. Herrera-Viedma, F.J. Cabrerizo, J. Kacprzyk, and W. Pedrycz. A review of soft consensus models in a fuzzy environment. *Information Fusion*, 17:4–13, 2014.
- [4] J. Kacprzyk. Group decision making with a fuzzy linguistic majority. *Fuzzy Sets and Systems*, 18(2):105–118, 1986.
- [5] Janusz Kacprzyk and Sławomir Zadrozny. Supporting consensus reaching processes under fuzzy preferences and a fuzzy majority via linguistic summaries. In *Preferences and Decisions*, pages 261–279. Springer, 2010.
- [6] J. B. Kruskal and M. Wish. *Multidimensional scaling*, volume 11. Sage, 1978.
- [7] Á. Labella, F. J. Estrella, and L. Martínez. AFRYCA 2.0: an improved analysis framework for consensus reaching processes. *Progress in Artificial Intelligence*, pages 1–14, 2017.
- [8] J. Lu, G. Zhang, D. Ruan, and F. Wu. *Multi-Objective Group Decision Making*. Imperial College Press, 2006.
- [9] S.A. Orlovsky. Decision-making with a fuzzy preference relation. *Fuzzy Sets and Systems*, 1(3):155–167, July 1978.
- [10] I. Palomares, F.J. Estrella, L. Martínez, and F. Herrera. Consensus under a fuzzy context: Taxonomy, analysis framework AFRYCA and experimental case of study. *Information Fusion*, 20:252–271, 2014.
- [11] R. M. Rodríguez, M. Espinilla, P. J. Sánchez, and L. Martínez. Using linguistic incomplete preference relations to cold start recommendations. *Internet Research*, 20(3):296–315, 2010.
- [12] R. M. Rodríguez and L. Martínez. A consensus model for group decision making with hesitant fuzzy linguistic information. In *Intelligent Systems and Knowledge Engineering (ISKE), 2015 10th International Conference on*, pages 540–545. IEEE, 2015.
- [13] R. M. Rodríguez, L. Martínez, and F. Herrera. A group decision making model dealing with comparative linguistic expressions based on hesitant fuzzy linguistic term sets. *Information Sciences*, 241(1):28–42, 2013.
- [14] R.M. Rodríguez, A. Labella, and L. Martínez. An overview on fuzzy modelling of complex linguistic preferences in decision making. *International Journal of Computational Intelligence Systems*, 9:81–94, 2016.
- [15] R.M. Rodríguez, L. Martínez, and F. Herrera. Hesitant fuzzy linguistic term sets for decision making. *IEEE Transactions on Fuzzy Systems*, 20(1):109–119, 2012.
- [16] M. Roubens. Fuzzy sets and decision analysis. *Fuzzy Sets and Systems*, 90(2):199–206, 1997.
- [17] S. Saint and J. R. Lawson. *Rules for Reaching Consensus. A Modern Approach to Decision Making*. Jossey-Bass, 1994.
- [18] S. Wold, K. Esbensen, and P. Geladi. Principal component analysis. *Chemometrics and intelligent laboratory systems*, 2(1-3):37–52, 1987.
- [19] M. Xia and Z. Xu. Managing hesitant information in GDM problems under fuzzy and multiplicative preference relations. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 21(06):865–897, 2013.
- [20] J. Yang, J. Liu, J. Wang, H. Sii, and W. Hong-Wei. Belief rule-based inference methodology using the evidential reasoning approach-rimer. *IEEE Transactions on systems, Man, and Cybernetics-part A: Systems and Humans*, 36(2):266–285, 2006.
- [21] L. A. Zadeh. Fuzzy sets. *Information and Control*, 8(3):338–353, 1965.
- [22] L. A. Zadeh. The concept of a linguistic variable and its application to approximate reasoning—i. *Information sciences*, 8(3):199–249, 1975.



# Ajuste a una progresión hipotética de aprendizaje

## Estudio de 3 casos de estudiantes de Magisterio

Itziar García-Honrado

Statistics, O. R. and Mathematics Didactics,  
University of Oviedo,  
Oviedo, Spain  
garciaitzar@uniovi.es

**Abstract—** Esta comunicación presenta un modelo matemático a través del uso de técnicas borrosas para describir el ajuste de los alumnos a progresiones hipotéticas de aprendizaje, parte fundamental de las conocidas Trayectorias Hipotéticas de Aprendizaje. En concreto, se hace uso del modelo granular lingüístico de un fenómeno. Para su implementación se distinguen distintos niveles de consecución de cada una de las etapas indicadas en la progresión hipotética de aprendizaje.

**Keywords—** evaluación; resumen lingüístico; trayectoria hipotética de aprendizaje

### I. INTRODUCCIÓN

El constructo de Trayectoria Hipotética de Aprendizaje (THA) pertenece al ámbito de la educación matemática, nace de la mano de Simon en 1995 [4], y permite al profesor de matemáticas modelar las distintas escenas por los que sus estudiantes hipotéticamente trascurren para la consecución de un objetivo de aprendizaje fijado a priori. Para ello, una vez fijado el objetivo, se diseñan unas tareas y se muestran los efectos esperados en los estudiantes hasta conseguir el objetivo. Dichos efectos, divididos en distintas etapas, constituirán una progresión hipotética de aprendizaje.

En posteriores estudios [5], Simon y Tzur experimentan en un aula el ajuste de los alumnos a la progresión hipotética de aprendizaje, mostrando cuando un alumno cumple o no cumple el efecto hipotético esperado en cada una de las etapas.

En la presente comunicación, proponemos realizar un estudio de este ajuste en términos imprecisos. Para ello, mostraremos el diseño de una THA y lo implementaremos en el aula, como se ha hecho en [1]. Por otro lado, diseñaremos unas rúbricas de evaluación que nos permita distinguir distintos niveles de consecución de la progresión hipotética de aprendizaje, así como el diseño de los elementos del modelo granular lingüístico que permitirán obtener una descripción lingüística del ajuste a la progresión hipotética de aprendizaje diseñada a priori de los alumnos. Finalmente, a modo de ejemplo, se mostrará el modelo desarrollado para valorar el ajuste de 3 alumnos a la progresión hipotética de aprendizaje.

### II. CONCEPTOS BÁSICOS

#### A. Progresión hipotética de aprendizaje

En una THA, se distinguen los siguientes componentes: el objetivo de aprendizaje, las tareas de aprendizaje y el proceso de aprendizaje hipotético; es decir, la predicción de cómo el pensamiento y la comprensión de los estudiantes evolucionan en el contexto de las actividades de aprendizaje [4]. Se destaca especialmente la importancia de la tarea, su diseño, los objetivos de aprendizaje, los conocimientos previos de los estudiantes y la progresión hipotética de aprendizaje. Así mismo, se considera relevante reconocer los efectos de la secuencia de tareas en la progresión de aprendizaje de la futura maestra [5].

A través de la THA, se muestran diferentes escenarios por los que los estudiantes pueden pasar transformando sus ideas intuitivas a una comprensión más formal de los conceptos matemáticos. Los niveles cada vez más sofisticados de razonamiento matemático evidencian aspectos de la progresión de la comprensión de un contenido específico. Por todo lo anterior, se considera que las THA constituyen un recurso instructivo muy eficaz para la enseñanza. La THA proporciona al profesorado recursos relevantes para acompañar a cada estudiante en el logro de su aprendizaje. Indican también el estado actual de aprendizaje del alumnado a través de una secuencia de estados de aprendizaje.

#### B. Modelo granular lingüístico de un fenómeno (GLMP)

Este modelo se sustenta dentro del campo de la lógica fuzzy. En consecuencia, no solo permite determinar si existe o no el ajuste de un alumno a la progresión hipotética existe, sino que permite asignar distintos grados de cumplimiento del ajuste.

Para determinar el ajuste utilizaremos el concepto de variable lingüística [8], entendida como aquella que puede tomar valores lingüísticos como Muy bajo / Bajo / Medio / Alto / Muy alto. Cada uno de ellos se representará, en nuestro caso, por un conjunto borroso continuo triangular,

debido a su simplicidad en la función (lineal definida por trozos) y a la posibilidad de ser definida por sus vértices. Al conjunto de los conjuntos borrosos que representa los valores que puede tomar la variable se le llama partición borrosa (Figura 1).

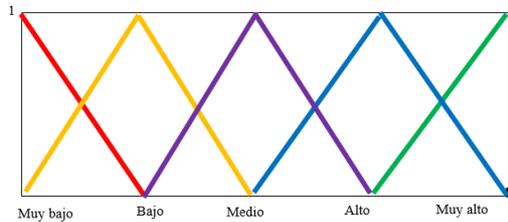


Figura 1: Conjuntos borrosos modelando las etiquetas lingüísticas

Combinando los problemas de control borroso con el actual auge de la conocida computación con palabras [9], surge el paradigma Modelo Granular Lingüístico de un fenómeno, o, en inglés, *Granular Linguistic Model of a Phenomenon* (GLMP) [6], el cual consiste en hacer resúmenes lingüísticos de fenómenos complejos como puede ser el ajuste de un estudiante a la progresión hipotética de aprovechamiento. En la literatura se pueden encontrar otras aplicaciones de este paradigma en la evaluación del aprendizaje de los alumnos [3].

### III. METODOLOGÍA

#### A. Diseño de la THA.

En esta investigación hemos construido la siguiente THA cuyo objetivo de aprendizaje es reconocer la generalización de patrones en la construcción de la secuencia geométrica de las figuras que aparecen en la obra artística "Composición aritmética" de Theo van Doesburg que puede observarse en la Figura 2. La actividad tiene un carácter competencial aunando arte y matemáticas, en concreto se eligió dicha obra, por las regularidades matemáticas que en ella aparecen [2,7] idóneas la búsqueda de patrones geométrico y su generalización.

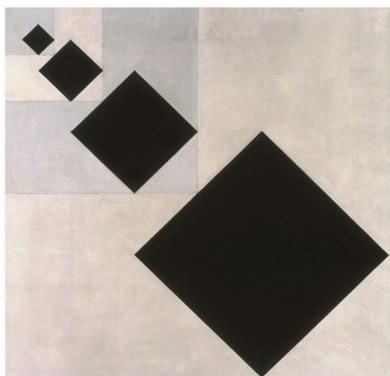


Figura 2. Arithmetic Composition. Theo van Doesburg, 1929-1930.

Las tareas y la progresión hipotética de aprendizaje se describen en la Tabla 1 y 2, respectivamente.

Tabla 1. Tareas de la THA

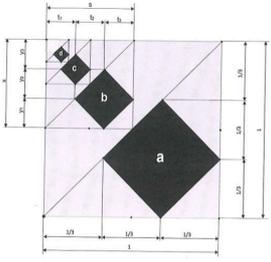
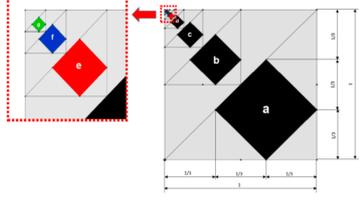
Tarea de aprendizaje	
Tarea 1. (Relacionada con la Etapa 1)	A partir de la obra de arte de la Figura 1, se ha construido la imagen que se muestra a continuación (la información que se incluye puede ayudar a resolver las tareas 5, 6 y 7).  Completa los datos que faltan en la figura, encontrando los valores de $x$ , $y_1$ , $y_2$ , $y_3$ , $s$ , $t_1$ , $t_2$ , $t_3$ . Justifica tu respuesta.
Tarea 2. (Relacionada con la Etapa 2)	(a) En el cuadro gris grande de la Figura 1, ¿cuántas figuras "a" pueden colocarse sin superponerse? (b) Dentro de la figura negra "a", ¿cuántas figuras negras "b" podrías colocar?
Tarea 3. (Relacionada con la Etapa 3)	En la Figura 1, (a) Calcula el área de la figura negra "a". (b) Calcula el área de la figura negra "b". (c) Calcula el área de las figuras negras "c" y "d".
Tarea 4. (Relacionada con la Etapa 4)	Si continuáramos la secuencia de las figuras negras podríamos dibujar otras, tal y como se muestra en la ampliación siguiente.  ¿Sabrías calcular las áreas de las nuevas figuras "e", "f" y "g"? Explica cómo lo has hecho.

Tabla 2. Progresión hipotética de aprendizaje.

Progresión hipotética de aprendizaje	
Etapa 1	Coordinación de la estructura espacial y la estructura numérica (a partir de las cotas) en la identificación de la secuencia de longitudes de los lados de los cuadrados grises involucrados en la obra artística.



Etapa 2	Coordinación de la estructura espacial y la numérica de la secuencia de los cuadrados, estableciendo relaciones entre las áreas de los cuadrados de la Figura 1.
Etapa 3	Cálculo del área de la sucesión de los cuadrados negros, relacionando el valor del área de un cuadrado con el valor del área del anterior, sigue un proceso de generalización cercana [Estadio1 de [10]].
Etapa 4	Abstracción de la coordinación espacial y numérica para el establecimiento de la relación funcional entre el área de los cuadrados negros [Estadio 2 de [10]].

- N0: No evidencia el cálculo de ningún área ni la relación que le permite obtener el área de uno a partir del área del anterior.
- N1: Calcula las áreas de algunos de los cuadrados de la sucesión.
- N2: Calcula las áreas de los cuadrados de la sucesión y muestra la relación que permitirá obtener el proceso de generalización cercana.
- N3: Calcula las áreas de los cuadrados de la sucesión, consiguiendo el valor del área de un cuadrado con el valor del área del anterior, es decir desarrolla el proceso de generalización cercana.

### B. Diseño de la rúbrica de evaluación

Distinguiremos distintos niveles en el logro de cada una de las etapas de la progresión hipotética de aprendizaje: no se logra (N0), se logra a nivel bajo (N1), a nivel medio (N2) o a nivel alto (N3).

Para ello se elabora una rúbrica de evaluación en la que se describe cada uno de estos niveles en las distintas etapas.

- Respecto a la Etapa 1:
  - N0: No identifica las longitudes de los lados de los cuadrados grises involucrados en el cuadro.
  - N1: Identifica parcialmente las longitudes de los lados de los cuadrados grises involucrados en el cuadro.
  - N2: Identifica la secuencia de longitudes de los lados de los cuadrados grises, pero no muestra coordinación entre la estructura espacial y la numérica.
  - N3: Identifica la secuencia de longitudes de los lados de los cuadrados grises mostrando coordinación entre la estructura espacial y la numérica.
- Respecto a la Etapa 2:
  - N0: No establece relaciones entre el área de los cuadrados negros del cuadro.
  - N1: Establece relaciones, únicamente, entre las áreas de una pareja de cuadrados del cuadro.
  - N2: Establece relaciones entre las áreas de los cuadrados del cuadro, pero no muestra coordinación entre la estructura espacial y la numérica.
  - N3: Establece relaciones entre las áreas de los cuadrados del cuadro mostrando coordinación entre la estructura espacial y la numérica.
- Respecto a la Etapa 3:

- Respecto a la Etapa 4:

- N0: No consigue llegar a una relación entre la posición que ocupan los cuadrados y su área.
- N1: Llega a una relación recursiva entre la posición que ocupa el cuadro y su área, es decir, basándose exclusivamente en el área del anterior.
- N2: Consigue una obtener una relación entre la posición que ocupan los cuadrados y su área, aunque no se utilice lenguaje matemático.
- N3: Establece una relación funcional entre la posición que ocupan los cuadrados y su área.

Es posible que no siempre sepamos con certeza que un alumno está en un determinado nivel en una etapa, podemos permitir que un alumno verifique características de dos o más niveles y demos como resultado final una media ponderada del nivel en el que se encuentra. Los niveles mostrados en la rúbrica se representan por conjuntos fuzzy, en este caso, triangulares. Asimilaremos N0 a la etiqueta lingüística nulo, N1 a bajo, N2 a medio y N3 a alto.

### C. Diseño del modelo granular lingüístico

Las rúbricas diseñadas formarán parte de los inputs de los sistemas de reglas fuzzy que se definen con el objetivo de conseguir el resumen lingüístico del ajuste de un alumno a la progresión hipotética de aprendizaje.

A partir de las rúbricas se definirán las percepciones de primer orden que serán las Etapas: 1, 2, 3 y 4.

Las etapas 1 y 2 se agregarán mediante un sistema de reglas, formando la percepción de segundo orden: Ajuste a los conceptos previos para el acercamiento a la relación entre los cuadrados de una sucesión. Dicha variable tomará 5 etiquetas lingüísticas Muy bajo / Bajo / Medio / Alto / Muy alto. Concretamente, el sistema se compondrá de 8 reglas:

1. Si en la Etapa 1 el nivel alcanzado por el alumno es nulo, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es muy bajo.

2. Si en la Etapa 2 el nivel alcanzado por el alumno es nulo, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es muy bajo.
3. Si en la Etapa 1 el nivel alcanzado por el alumno es bajo y en la Etapa 2 el nivel alcanzado por el alumno es bajo, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es bajo.
4. Si en la Etapa 1 el nivel alcanzado por el alumno es bajo y en la Etapa 2 el nivel alcanzado por el alumno es medio, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es medio.
5. Si en la Etapa 1 el nivel alcanzado por el alumno es medio y en la Etapa 2 el nivel alcanzado por el alumno es bajo, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es medio.
6. Si en la Etapa 1 el nivel alcanzado por el alumno es medio y en la Etapa 2 el nivel alcanzado por el alumno es medio, el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es alto.
7. Si en la Etapa 1 el nivel alcanzado por el alumno es alto, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es muy alto.
8. Si en la Etapa 2 el nivel alcanzado por el alumno es alto, entonces el ajuste de los conceptos previos a la progresión hipotética de aprendizaje es muy alto.

El método de resolución del sistema de reglas será el método Mamdani aplicando el producto a las sentencias Si/Entonces. La Figura 3 muestra la superficie de control del sistema de reglas.

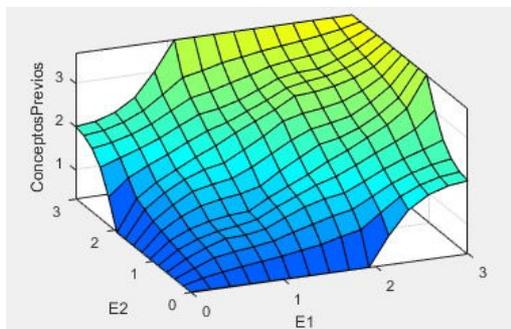


Fig.3. Superficie de control para el sistema de reglas descrito.

Las etapas 3 y 4 se agregan mediante un sistema de 8 reglas, análogo al anterior, para originar la percepción de segundo orden: Ajuste al proceso de generalización según Zapatera y Callejo [10] (cerca y funcional). Dicha variable se define a través de 5 etiquetas lingüísticas del mismo modo que la anterior.

Finalmente, a través de otro sistema de 13 reglas, similar a los anteriores, a partir de las dos percepciones de segundo orden

generadas, se definirá la percepción general sobre el ajuste a la progresión hipotética de aprendizaje de la progresión que haya seguido el alumno.

Todos los sistemas de reglas involucrados se han implementado en Matlab. Ese engranaje permite la construcción de una descripción lingüística del ajuste de cada alumno a la progresión hipotética de aprendizaje, del siguiente modo:

*El alumno A se ha ajustado a un nivel Muy bajo/Bajo/Medio/Alto/Muy alto a la progresión hipotética de aprendizaje en las tareas encaminadas a trabajar los conceptos previos para el acercamiento a la relación entre los cuadrados de una sucesión. En el caso del proceso de generalización, el ajuste con la progresión hipotética de aprendizaje ha sido Muy bajo/Bajo/Medio/Alto/Muy alto. Con todo ello, podemos hablar de un ajuste global a la progresión hipotética de aprendizaje Muy bajo/Bajo/Medio/Alto/Muy alto.*

Además, se asignará un valor numérico al ajuste global en el continuo [0,4] donde 0 representará el menor y 4 el mayor ajuste posible.

#### IV. CONTEXTO DE LA EXPERIMENTACIÓN

El experimento de enseñanza se llevó a cabo en una sesión de 2 horas en un aula con estudiantes del Grado de Maestro el pasado curso, 2017-2018, en la Universidad de Oviedo.

Las tareas que se recoge en este trabajo pertenecen a la segunda sesión y parte central de una secuencia de actividades relacionadas con la obra de arte de Theo van Doesburg realizadas a lo largo de tres sesiones.

Participaron 33 alumnos en el experimento de los cuales se seleccionaron tres casos distintos en los que podemos ver distintos niveles de ajuste a la progresión hipotética de aprendizaje. Nos referiremos a los casos de los alumnos con pseudónimo: Ángela, Andrea y José.

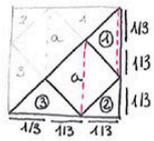
#### V. CASOS SELECCIONADOS

##### A. Ajuste a la progresión hipotética de aprendizaje de Ángela

Ángela realiza exclusivamente las primeras actividades de la tarea. Dado el alto nivel alcanzado en las mismas, la falta de las demás tareas podría estar motivada por un inadecuado ajuste del tiempo de realización.

En la Etapa 1, Ángela se encuentra en un nivel alto ya que justifica las medidas pedidas a través de la imagen del cuadro.

Respecto a la Etapa 2, Ángela muestra las relaciones pedidas mostrando una coordinación entre la estructura gráfica y numérica pues se apoya en la imagen para calcular las relaciones como se muestra en la Figura 4. Por lo tanto, el nivel alcanzado en esta etapa es alto.



En total 4,5 cuadrados

Teniendo en cuenta esta parte del dibujo, podemos ver que la diagonal de  $a$  es igual que el lado mayor del triángulo 1 ( $1/3$ ). Por lo tanto, si unimos los triángulos 1 y 3, formamos un segundo cuadrado. El triángulo 2 es la mitad de los triángulos 1 y 3 ( $1/3$ ).

Si unimos estos datos y tenemos en cuenta que es un cuadrado completo, tenemos 2 cuadrados  $a$ , 2 cuadrados partidos ( $1/3$  en cada mitad) y medio cuadrado (resultado de la unión del triángulo 2 con el otro).

Figura 4. Explicación dada por Ángela justificando la relación entre la figura "a" y el cuadro gris grande.

Sin embargo, en la Etapa 3 se encuentra en un nivel entre bajo y medio, ya que simplemente calcula las áreas de algunos cuadrados negros de la sucesión, no obstante, en este cálculo, muestra la relación que permite obtener el proceso de generalización cercana, ya que relaciona estas respuestas con la relación entre dos cuadrados negros consecutivos. El nivel alcanzado en la Etapa 4, es nulo, pues la alumna no realiza la tarea.

Tras el análisis de la resolución de Ángela, las percepciones de primer nivel en este caso serán: 3 (E1), 3 (E2), 1.5 (E3), y 0(E4). A partir de estos datos, se implementan los sistemas de reglas involucrados. En la Figura 5, se recoge el sistema de reglas que permite obtener la percepción global.

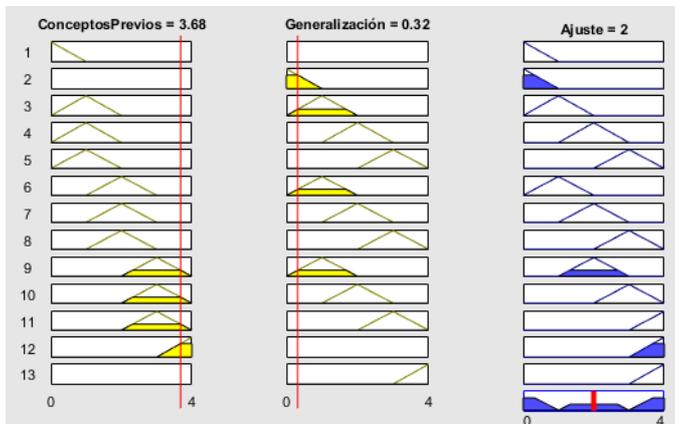


Figura 5. Ajuste global a la progresión hipotética de aprendizaje para Ángela

El resumen lingüístico para el caso de Ángela sería:

Ángela se ha ajustado a un nivel muy alto a la progresión hipotética de aprendizaje en las tareas encaminadas a trabajar los conceptos previos para el acercamiento a la relación entre los cuadrados de una sucesión. En el caso del proceso de generalización, el ajuste con la progresión hipotética de aprendizaje ha sido entre Bajo y Medio. Con todo ello, podemos hablar de un ajuste global a la progresión hipotética de aprendizaje Medio. (2/4)

### B. Ajuste a la progresión hipotética de aprendizaje Andrea

Andrea, en la Etapa 1, está en un nivel entre medio y alto, ya que escribe directamente el resultado justificándolo por: "Estos datos los obtengo de observar los datos que ya sabemos". Así que, aunque no hay evidencias de las operaciones que hace para la obtención de los datos, interpretamos que puede existir una coordinación entre la estructura espacial y numérica.

En la Etapa 2, establece la relación que hay entre las áreas del cuadrado "a" y el cuadrado gris grande, a través de operaciones del cálculo de áreas y sumas repetidas del área de "a" hasta aproximarse a 1, obteniendo 4.5. Averigua la relación entre los cuadrados negros a través de razonamientos con la medida de los lados de los mismos. Por lo tanto, establece las relaciones, aunque interpretamos que, a través de la estructura numérica, no de la espacial. Entonces, el nivel es medio.

En la Etapa 3, se asigna un nivel entre Bajo y Medio, ya que calcula las áreas de los cuadrados, pero no muestra la relación que le permite obtener la generalización cercana.

Finalmente, en la Etapa 4, realiza una generalización cercana evidenciando la relación entre cuadrados consecutivos de la sucesión. Por consiguiente, llega a una relación recursiva entre la posición que ocupa el cuadro y su área. Así pues, está en un nivel Bajo.

Con todo esto, las percepciones de primer nivel en este caso serán: 2.5 (E1), 2 (E2), 1.5 (E3), y 1(E4). En la Figura 6, se muestra el último sistema de reglas que permite generar el ajuste global a la progresión hipotética de aprendizaje.

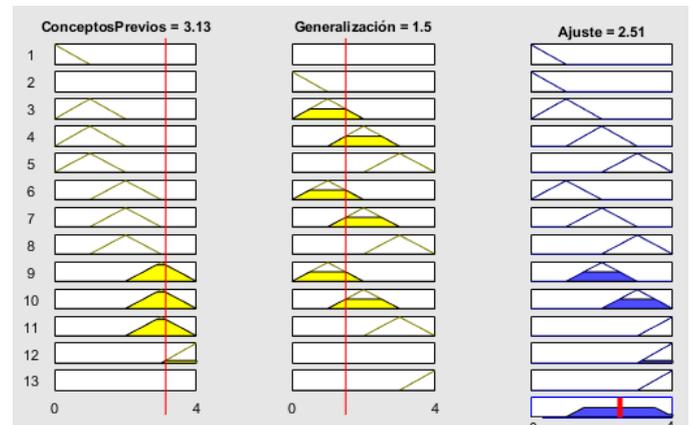


Figura 6. Ajuste global a la progresión hipotética de aprendizaje para Andrea

El resumen lingüístico para el caso de Andrea sería:

Andrea se ha ajustado a un nivel alto a la progresión hipotética de aprendizaje en las tareas previas encaminadas a trabajar los conceptos para el acercamiento a la relación entre los cuadrados de una sucesión. En el caso del proceso

de generalización, el ajuste con la progresión hipotética de aprendizaje ha sido entre Bajo y Medio. Con todo ello, podemos hablar de un ajuste global a la progresión hipotética de aprendizaje entre Medio y Alto. (2.51/4

C. Ajuste a la progresión hipotética de aprendizaje de José

Según la rúbrica de evaluación José alcanza un nivel muy alto en todas las etapas. En la Etapa 1, además de identificar la secuencia de longitudes, coordina las estructuras espacial y numérica justificando gráfica y numéricamente los resultados: “todas son 1/3 de 1/2, por lo tanto 1/6”. La forma de proceder en la Etapa 2 es similar a la resolución de Ángela, realiza explicaciones gráficas muy similares a su compañera y las coordina con la estructura numérica, por tanto, se encuentra en un nivel alto.

Respecto a las etapas 2 y 3, José muestra un nivel alto. En la Etapa 3, utiliza la relación entre cuadrados negros para calcular el área del siguiente de la sucesión, por lo tanto desarrolla el proceso de generalización cercana y alcanza un nivel alto. En la Etapa 4, establece la relación funcional entre la posición que ocupan los cuadrados en la sucesión y su área, llegando a la fórmula general que se muestra en la Figura 7.

$$\begin{aligned}
 a=1 &\rightarrow \frac{1}{18} \\
 b=2 &\rightarrow \left(\frac{1}{4} \times \frac{4}{18}\right) \\
 c=3 &\rightarrow \left(\frac{1}{4^2} \times \frac{4}{18}\right) \\
 d=4 &\rightarrow \left(\frac{1}{4^3} \times \frac{4}{18}\right)
 \end{aligned}
 \Rightarrow \text{área } n = \left(\frac{1}{4^{n-1}} \cdot \frac{4}{18}\right) u^2$$

Figura 7. Relación funcional establecida por José.

Así pues, las percepciones de primer nivel en este caso serán: 3 (E1), 3 (E2), 3 (E3), y 3(E4), de las que se infieren las percepciones de segundo nivel (ambas con centroide del nivel: 3.68) y la percepción global con un nivel muy alto (3.65) como puede apreciarse en la Figura 8.

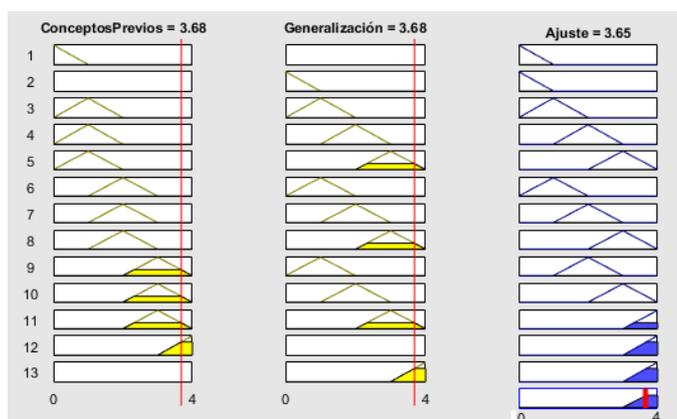


Figura 8. Ajuste global de la progresión hipotética de aprendizaje para José

El resumen lingüístico para este caso es:

José se ha ajustado a un nivel muy alto a la progresión hipotética de aprendizaje en las tareas encaminadas a trabajar los conceptos previos para el acercamiento a la relación entre los cuadrados de una sucesión. En el caso del proceso de generalización, el ajuste con la progresión hipotética de aprendizaje ha sido muy alto. Con todo ello, podemos hablar de un ajuste global a la progresión hipotética de aprendizaje muy alto. (3.65/4)

VI. CONCLUSIONES

En este trabajo, se muestra cómo valorar las resoluciones de alumnos a tareas enmarcadas dentro del marco de las Trayectorias Hipotéticas de Aprendizaje y mostrar el ajuste de las mismas a progresiones hipotéticas de aprendizaje diseñadas a priori. El ajuste, se expresa a partir de términos lingüísticos modelando los distintos modos de ajuste a través de etiquetas lingüísticas. Esto resulta beneficioso en comparación con estudios previos en los que sólo se recogía si había o no ajuste simplificando la riqueza de las resoluciones de los alumnos y no valorando los distintos niveles de adquisición.

AGRADECIMIENTOS

El estudio forma parte del Proyecto EDU2015-65378-P, MINECO.

REFERENCIAS

- [1] García-Honrado, I., Clemente, F., Vanegas, Y., Badillo, E. y Fortuny, J.M. “Análisis de la progresión de aprendizaje de una futura maestra” Actas del Congreso XXII SEIEM, aceptado para su publicación, Septiembre 2018.
- [2] Pim, D. “Some Notes on Theo van Doesburg (1883-1931) and his Arithmetic Composition 1” *For the learning of Mathematics*, 2001, vol. 21(2), pp. 31-36.
- [3] Sanchez-Torrubia, M. G., Torres-Blanc, C. y Triviño, G. “Modelo lingüístico del aprendizaje para la evaluación automática basada en criterios” En F. Bobillo, H. Bustince, F. J. Fernández, y E. Herrera-Viedma (Eds.), *Actas del XVII ESTYLF*, pp. 417-422, Zaragoza, 2014.
- [4] Simon, M. A. “Reconstructing mathematics pedagogy from a constructivist perspective” *Journal for Research in Mathematics Education*, 1995, vol. 26, pp.114-145.
- [5] Simon M.A. y Tzur, R. “Explicating the Role of Mathematical Tasks in Conceptual Learning: An Elaboration of the Hypothetical Learning Trajectory” *Mathematical thinking and learning*, 2004, vol. 6(2), pp.91-104.
- [6] Triviño, G. y Sugeno, M “Towards linguistic descriptions of phenomena” *International Journal of Approximate Reasoning*, 2013, vol. 54(1), pp.22-34.
- [7] Walter, M. “Looking at a Painting with a mathematical Eye” *For the learning of Mathematics*, 2001, vol. 21(2), pp.26-30.
- [8] Zadeh, L. A. “The concept of a linguistic variable and its application to approximate reasoning – III”. *Information Sciences*, 1975, vol. 9(1), pp. 43-80.
- [9] Zadeh, L. A. “Fuzzy logic= computing with words” *Fuzzy Systems, IEEE Transactions on fuzzy systems*, 1996, vol. 4(2), 103-111.
- [10] Zapatera, A. y Callejo, M.L. “Prospective primary teachers’ noticing of students’ understanding of pattern generalization” *J. Math Teacher Education*, Springer, 2017, vol. 20, pp. 309-333.



# Caracterizando a los usuarios a través de sus opiniones

Jesus Serrano-Guerrero, Francisco P. Romero, Jose Ruiz-Morilla, Jose A. Olivas

Departamento de Tecnologías y Sistemas de Información  
Escuela Superior de Informática (UCLM), Ciudad Real, 13071, España  
jesus.serrano@uclm.es, joseangel.olivas@uclm.es, franciscop.romero@uclm.es

**Resumen**—El análisis de sentimientos basados en aspectos permite detectar comportamientos de ciertos usuarios. Estos comportamientos necesitan ser modelado para poder entenderse la opinión final sobre un producto o servicio. Este artículo propone el modelado de cada opinión final en base a la agregación borrosa de las distintas opiniones sobre los distintos aspectos que conforman el producto opinado. Igualmente propone algunas aplicaciones para dicho aplicaciones.

**Palabras clave**—análisis de sentimientos basado en aspectos; operadores OWA; perfil de usuario

## I. INTRODUCCION

Cada vez es más frecuente el uso de servicios, especialmente en Internet gracias a plataformas como Amazon o Tripadvisor, que permiten expresar opiniones a los usuarios sobre distintos productos. Detrás de estas opiniones se pueden ocultar distintos comportamientos que es necesario que sean caracterizados con el fin de entender los distintos usuarios y las situaciones en las cuales hacen un comentario determinado u otro.

El campo del Análisis de Sentimientos se centra principalmente en detectar posibles expresiones que sean susceptibles de ser interpretadas como opiniones y cuantificar el grado en el que cada opinión sea más o menos positiva, entre otras tareas. La detección de las opiniones se puede realizar a nivel de sentencia, de aspecto o de documento.

Este trabajo está más centrado en la detección a nivel de aspecto, porque permite ver cómo los usuarios pueden expresar sus preferencias acerca de determinadas características de un producto o servicio descartando otros. Por ejemplo, si un usuario que acaba de adquirir un teléfono hace una crítica feroz acerca de su batería, esto puede suponer que adquirió el teléfono pensando que la batería era uno de sus puntos fuertes y a la vez, se podría inferir que una de las preferencias del usuario era dicha batería. Sin embargo, si el usuario a pesar de hacer una queja sobre un aspecto como podría ser la cámara frontal del móvil no es demasiado efusivo, podría interpretarse que el producto no es bueno, pero tampoco era un detalle importante para el usuario a la hora de tomar su decisión final sobre comprar un móvil u otro.

Todos estos detalles hacen que para entender la opinión final de un usuario sobre un producto o servicio, sea necesario tener en cuenta la importancia de cada aspecto y el grado de positividad o negatividad emitido hacia cada uno de ellos. Es por ello, que se propone el modelado de una opinión final como la agregación borrosa de las opiniones parciales emitidas sobre cada aspecto.

La principal contribución de este artículo es una visión acerca de algunos posibles comportamientos de los usuarios cuando expresan opiniones, especialmente, sobre productos y servicios que compran o utilizan, así como una posible aproximación borrosa que permitiría el modelado de dichos comportamientos, y sus posibles aplicaciones.

El artículo está organizado en las siguientes secciones: la sección II se corresponde con el estado del arte, la sección III presenta la principal motivación del artículo, la sección IV presenta cuál sería la metodología para agregar las distintas opiniones y dar una conclusión final al usuario sobre un producto, la sección V presentará algunas aplicaciones de uso y finalmente, algunas conclusiones serán remarcadas.

## II. ESTADO DEL ARTE

Según Cambria, el Análisis de Sentimientos puede ser considerado como un problema de Procesamiento de Lenguaje Natural (PLN) muy restringido, en el que sólo es necesario entender los sentimientos positivos o negativos respecto a cada frase y/o las entidades o temas objetivo [1]. Sin embargo, a pesar de ser un problema restringido, todos los trabajos en este campo, así como todos los trabajos en Recuperación de Información, siempre luchan con problemas de PLN no resueltos (manejo de la negación, reconocimiento de entidades con nombre, desambiguación del sentido de la palabra,...) que son esenciales para detectar claves del lenguaje como la ironía o el sarcasmo [2], y en consecuencia, para encontrar y valorar sentimientos.

Uno de los principales aspectos que debe abordar la PLN son los diferentes niveles de análisis. Dependiendo de si el objetivo del estudio es un texto completo o un documento, una o varias frases enlazadas, o una o varias entidades o aspectos de esas entidades, se pueden realizar diferentes tareas de PLN y Análisis de Sentimientos. Por lo tanto, es necesario distinguir

tres niveles de análisis: (i) nivel de documento, (ii) nivel de frase y (iii) nivel de entidad/aspecto.

A nivel de documento se considera que un documento es una opinión sobre una entidad o aspecto de la misma. Este nivel está asociado con la tarea llamada clasificación de sentimientos a nivel de documento [3]–[6]. Sin embargo, si un documento presenta varias frases que tratan de diferentes aspectos o entidades, entonces el nivel de oración es más adecuado. El nivel de la oración está relacionado con la clasificación de la subjetividad de la tarea; considera cada oración como una opinión positiva, negativa o neutral [7]–[10]. Y finalmente, cuando se necesita información más precisa, entonces surge el nivel de entidad/aspecto. Es el nivel de grano más fino, considera un objetivo sobre el que el ponente de opinión expresa una opinión positiva o negativa. Este último nivel es posiblemente el más complejo, ya que es necesario extraer con gran precisión muchas características, como las fechas o el lapso de tiempo, las diferentes características/espectáculos y entidades a tener en cuenta, así como las relaciones entre ellas, los formadores de opinión y sus características, etc. Está estrechamente relacionado con tareas como Opinion Mining y Opinion Summarization [9], [10].

Muchas tareas surgen vinculadas al Análisis de Sentimientos. Algunas de ellas están estrechamente relacionadas y es difícil separarlas claramente porque comparten muchos aspectos. Los más importantes son:

1. Clasificación de sentimientos: también llamada orientación de sentimientos, orientación de opinión, orientación semántica o polaridad de sentimientos [11]. Se basa en la idea de que un documento/texto expresa la opinión de un titular sobre la entidad y trata de medir el sentimiento de ese titular hacia la entidad. Por lo tanto, consiste principalmente en clasificar las opiniones en tres categorías principales: positivas, negativas o neutras. Parece una tarea simple; sin embargo, es una tarea compleja, especialmente cuando las opiniones provienen de múltiples dominios o idiomas [12], [13]. Esta tarea está estrechamente relacionada con la predicción de la valoración de los sentimientos, que consiste en medir la intensidad de cada sentimiento.
2. Clasificación de subjetividad. Consiste principalmente en detectar si una frase dada es subjetiva o no. Una frase objetiva expresa información objetiva, mientras que una frase subjetiva puede expresar otro tipo de información personal como opiniones, evaluaciones, emociones, creencias, etc. Además, las frases subjetivas pueden expresar sentimientos positivos o negativos, pero no todas lo hacen. Esta tarea puede ser vista como un paso previo a la clasificación de los sentimientos. Una buena clasificación de la subjetividad puede asegurar una mejor clasificación de los sentimientos [14]–[17].
3. Resumen de opiniones. Se centra especialmente en extraer las características principales de una entidad compartida dentro de uno o varios documentos y los sentimientos al respecto [18]. Por lo tanto, se pueden distinguir dos perspectivas en esta tarea: la integración de un solo documento y la integración de varios documentos. La integración de un solo documento consiste en analizar hechos internos presentes en el documento analizado, por ejemplo, cambios en la orientación de los sentimientos a lo largo del documento o vínculos entre las diferentes entidades/características encontradas, y principalmente mostrar aquellos textos que mejor los describen. Por otro lado, en la integración multidocumento, una vez detectadas las características y entidades, el sistema debe agrupar y/o ordenar las diferentes frases que expresan sentimientos relacionados con dichas entidades o características. El resumen final puede presentarse en forma de gráfico o texto que muestre las principales características/entidades y cuantifique el sentimiento con respecto a cada una de ellas de alguna manera, por ejemplo, agregando intensidades de sentimientos o contando el número de frases positivas o negativas [19], [20].
4. Recuperación de opiniones. Intenta recuperar documentos que expresan una opinión sobre una consulta determinada. En este tipo de sistemas, se requieren dos puntajes para cada documento, el puntaje de relevancia frente a la consulta y el puntaje de opinión sobre la consulta, y ambos se utilizan generalmente para clasificar los documentos [21], [22].
5. Sarcasmo e ironía. Se centra en detectar afirmaciones con contenido irónico y sarcástico. Esta es una de las tareas más complicadas en este campo, especialmente debido a la falta de acuerdo entre los investigadores sobre cómo se puede definir formalmente la ironía o el sarcasmo [2], [23], [24].
6. Otros. Además de las actividades anteriormente mencionadas, existen otras tareas relacionadas con el Análisis de Sentimientos, como por ejemplo, la detección de género o autoría, que trata de determinar el género o la persona que ha escrito un texto/opinión [25], [26], la detección de spam de opinión, que trata de detectar opiniones o reseñas que contienen contenidos no confiables publicados para distorsionar la opinión pública hacia personas, empresas o productos [27]–[29], o la identificación de temáticas en función de los términos referidos a sentimientos [30].

III. MOTIVACIÓN

Son muchas las aplicaciones y páginas web que permiten al usuario expresar sus opiniones. Analizando detenidamente las distintas opiniones de forma general, se puede observar que los comportamientos de los usuarios pueden ser muy diversos, pudiendo establecerse distintos tipos de usuario dependiendo de las formas en las que emiten sus opiniones.

De igual manera, son muchas las formas en las que un usuario puede expresar su opinión. Por ejemplo, entre las más típicas podemos encontrar el uso de conjuntos de estrellas como puede verse en muchas páginas webs de venta de productos como Amazon<sup>1</sup> o Joom<sup>2</sup>:



Fig. 1. Puntuación mediante estrellas

o mediante una barra que permita establecer el grado de conformidad con respecto a un aspecto concreto:



Fig. 2. Barra de puntuación

entre otros posibles mecanismos. Como puede observarse, estos mecanismos permiten de una manera fácil, rápida e intuitiva expresar una opinión, sin embargo, carecen de cierta expresividad que si provee el lenguaje natural. Por ejemplo, las estrellas vistas anteriormente podrían ir acompañadas de distintas etiquetas lingüísticas {No satisfecho, Poco satisfecho, Medianamente satisfecho, Satisfecho, Muy satisfecho}, que pueden resultar más intuitivas e interpretables que las estrellas o su representación numérica: 1 estrella, 2 estrellas, 3 estrellas, etc.

Esto se puede ilustrar mediante el siguiente ejemplo (Figura 3) sacado de la página web TripAdvisor<sup>3</sup>:



Fig. 3. Opinión con puntuación poco precisa

Si se observan las puntuaciones, la estancia parece haber sido perfecta porque son máximas respecto a todos los aspectos posibles (valor, localización, habitaciones, limpieza, ....). Sin embargo, si se observan los comentarios esto no es así. El tamaño de la habitación era bueno pero no excelente. Lo mismo ocurre con la calidad del sueño, fue buena pero no excelente. Se podría pensar que este usuario utilizaría la etiqueta lingüística “bueno” como símbolo para representar la máxima calidad, sin embargo, si se lee la primera frase, la localización era “excelente”, por lo que gradación de las puntuaciones podría llegar hasta ese extremo.

A. Algunos posibles tipos de usuarios

Ya hemos visto algún tipo de usuario como puede ser el usuario poco preciso de la imagen anterior, pero podemos ver más posibles usuarios. Por ejemplo, si miramos a la siguiente opinión que expresa de forma fehaciente que el hotel es fantástico:



Fig. 4. Opinión excesivamente positiva

contrasta con la siguiente opinión emitida con una semana de diferencia, donde el usuario afirma que el mismo hotel es horrible:

<sup>1</sup> www.amazon.com  
<sup>2</sup> www.joom.com  
<sup>3</sup> www.tripadvisor.com

Reviewed 20 June 2014

DISGUSTING ROOMS, NO POOL AND EXCEPTIONALLY RUDE MANAGER TRIED TO OVERCHARGE Me.

I booked a single room, rung to confirm my booking the day of arrival only to be told I'd booked a double. I tried to tell the woman (whom I now know to be the manager) there must be a mistake she argued with me, told me that her staff would not have made that mistake then told me I should be more careful with my credit card payments! After telling me that I couldn't have a single room originally, once I made it clear I wasn't paying extra for the double, she magically found a single room.

On arrival the receptionist admitted there had been a mistake when I phoned, that I had indeed booked a single room and they'd mistakenly changed it double. The single room I got must have been the last one available, it's absolutely disgusting. There are holes in the wall, hair in the toilet, the carpet on the stairs looks like the cleaner died in 1975 and it hasn't seen a vacuum since.

I booked this hotel instead the other ones in town for the pool, which again, I checked was available when booking. Arriving and intending to hear straight for the pool, of course it's out of order.

Disgusting hotel, awful manager who is happy to sarcastically tell you to me more careful with your credit card after trying to charge you extra. Wish I'd stayed at the Holiday Inn.

Stayed: June 2014

- Value
- Location
- Rooms
- Cleanliness
- Service

Fig. 5. Opinión excesivamente negativa

Leyendo detenidamente ambos comentarios, puede verse cómo se comparan cosas como el personal o las instalaciones con perspectivas absolutamente distintas. En este caso, podría pensarse que los usuarios pueden ser falsos, es decir, un usuario expresa su opinión simplemente para denigrar la calidad de un hotel, lo que podría conocerse como un “hater”, o un usuario podría intentar mejorar la calidad de un hotel bien porque tiene algún interés escondido, en este caso sería un “lover”. Igualmente, podría ser, simplemente, que el estado de ánimo con el que se emitieron las opiniones no permite expresar de forma excesivamente realista cuál fue la situación real del hotel, o sí.

IV. PROPUESTA

Como puede observarse, modelar el comportamiento de los usuarios puede ser complejo y hay distintos factores a tener en cuenta. Entre estos factores pueden destacarse:

- la importancia que tiene para cada usuario un aspecto determinado dentro del producto del que se está opinando.

- La opinión que tiene el usuario de cada uno de los aspectos que conforman un objeto.
- La opinión global de un producto o servicio vista como el resultado de la agregación de cada uno de los aspectos en función de la importancia.

A. Opinión sobre un aspecto

Así pues, matemáticamente un producto podría definirse como un conjunto A de N aspectos:

$$A = \{A_1, A_2, A_3, \dots, A_N\}$$

Sobre cada aspecto es posible emitir una opinión que puede ser representada mediante un conjunto de etiquetas lingüísticas  $\{S_1, S_2, S_3, \dots\}$ . Estas etiquetas lingüísticas podrían ser definidas mediante número triangulares borrosos NTB, donde  $S_i$  se puede representar por el número  $NTB_i = (a_i, b_i, c_i)$ . La distribución de los parámetros puede dar lugar a un conjunto de etiquetas balanceado o no. Esto puede permitir tener más capacidad a la hora de filtrar a los usuarios y a los vendedores de los productos.

Véase el siguiente ejemplo. Si la valoración de las opiniones de cada aspecto fuera usando el siguiente conjunto balanceado de 5 etiquetas:

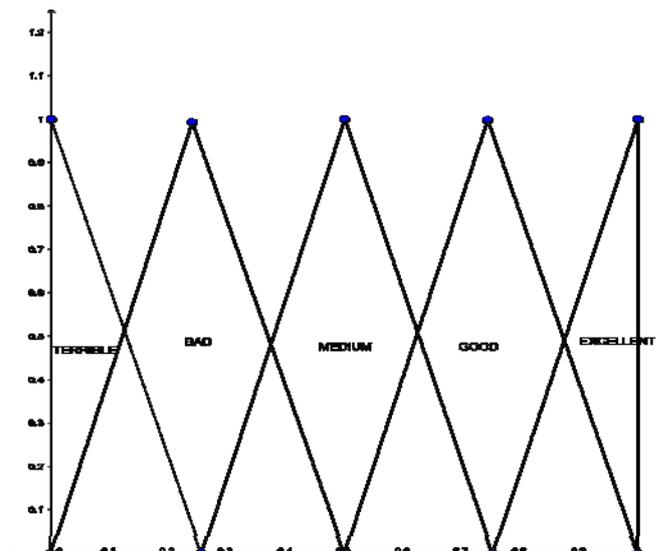


Fig. 6. Distribución de etiquetas balanceada

Podría corresponder intuitivamente con el sistema de estrellas visto en plataformas como Amazon (ver Figura 1), donde una opinión con una única estrella representa la peor valoración, es decir, el primer conjunto de la figura (TERRIBLE), y 5 estrellas representa la mejor valoración, en este caso el último conjunto (EXCELENTE).

Sin embargo, si se utilizara un conjunto de etiquetas como el visto en la siguiente figura, el usuario tendría un mayor poder discriminación, primero porque existen más etiquetas con las que valorar una opinión y segundo porque el soporte de las etiquetas que representan opiniones positivas es mucho menor, por lo que el usuario sería mucho más exigente a la

hora de decir si un producto es BUENO, MUY BUENO o EXCELENTE.

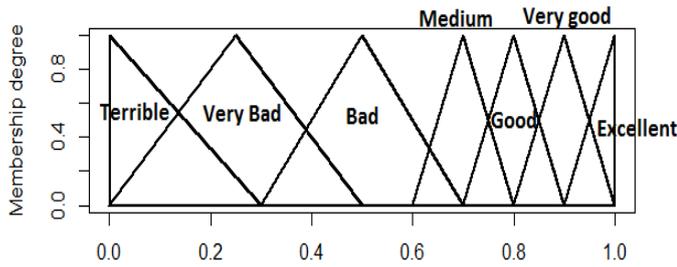


Fig. 7. Distribución de etiquetas no balanceada

**B. Importancia de cada aspecto**

Cada usuario puede considerar cada aspecto según su propio criterio. Suponer un teléfono móvil, ¿cuál es el aspecto más importante a la hora de comprarlo? Cada usuario pensará uno distinto, unos querrán que la cámara sea de alta definición para hacer fotos, a otros la cámara no les importará y preferirán que la batería le dure más tiempo, otros preferirán que tenga mucha memoria para almacenar muchos archivos, o la que conexión sea 5G, etc.

Por tanto, a la hora de emitir la opinión general sobre un producto, cada aspecto no tiene por qué pesar lo mismo. Así, es necesario modelar el peso de cada aspecto según el usuario.

Este peso puede ser calculado de muchas maneras, por ejemplo, a través de un valor numérico dentro de una escala [0,1]. Siguiendo con el ejemplo del teléfono se podría dar las siguientes importancias a estos posibles aspectos:

- Batería: 0.5
- Pantalla: 0.2
- Conectividad 5G: 0.1
- Cámara: 0.2

En este caso, como puede verse, todos los pesos suman 1, y el más importante sería en este caso el aspecto de la batería, mientras que la conectividad 5G no parece ser nada relevante para este usuario.

Siguiendo una aproximación más intuitiva, la importancia podría ser una variable representada mediante un conjunto de etiquetas  $\{S_1, S_2, S_3, \dots\}$ , las cuales nuevamente podrían ser definidas mediante número triangulares borrosos NTB, donde  $S_i$  se puede representar por el número  $NTB_i = (a_i, b_i, c_i)$ . La distribución puede ser igual balanceada o no, y como ejemplo podría darse el siguiente conjunto, en el cual el usuario podría seleccionar si un aspecto para él es irrelevante, simplemente importante o de vital importancia:

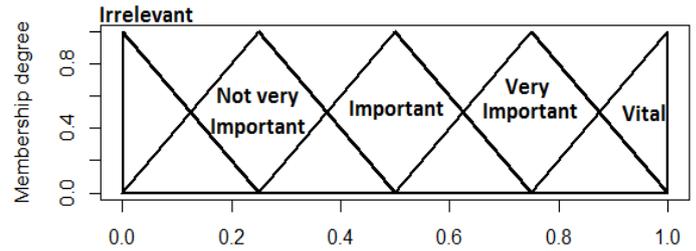


Fig. 8. Ejemplo de etiquetas para medir la importancia de un aspecto

Dependiendo de la forma en la que se mida la importancia, determinará cómo se calcula la opinión general que puede tener un usuario respecto a un producto.

**C. Opinión general: Agregación de aspectos**

Una vez que el usuario ha determinado cuál es la importancia de cada aspecto, y ha opinado sobre cada uno de ellos, es necesario agregar todas las opiniones individuales pero, teniendo en cuenta cuál es más importante que la otra.

Para ello, se puede proponer el uso de los operadores OWA [31]. Dependiendo de cómo se hayan obtenidos los distintos pesos y las valoraciones de cada aspecto, se podrán utilizar distintas familias de operadores OWA.

En el caso, por ejemplo, de medir a través de la calificación mediante estrellas (ver Figura 1) y que los pesos sean introducidos como valores en el rango [0,1] sumando en su conjunto 1, al ser todos los valores de naturaleza crisp, se podría utilizar un operador OWA clásico. Sin embargo, en el caso de que se utilizaran conjuntos borrosos para obtener los parámetros necesarios, serían necesarios acceder a familias como los OWA de Tipo-1 [32].

**V. APLICACIONES**

A través de la propuesta anterior, es posible modelar de una forma más fehaciente, cuál puede ser la opinión general de un usuario cuando valora un producto. Entre las aplicaciones que podría encontrarse a esta propuesta podrían mencionarse:

- Detección y clasificación de usuarios: Poder clasificar a los usuarios según sus opiniones puede resultar interesante desde distintos puntos vista. Por ejemplo, un usuario que siempre puntúa positivamente los productos de una marca y negativamente los de la competencia, no tiene por qué implicar que sus opiniones no sean válidas, simplemente es su forma de pensar. Así, un sistema de recomendaciones tendría más información para saber qué productos recomendarle y cuáles no.
- Asignación del grado de confianza de un usuario: Como consecuencia de lo anterior, las opiniones de todos los usuarios no parecen ser igualmente fiables, por lo que la descripción de cada usuario a través de un grado de confiabilidad podría permitir descartar las opiniones de ciertos usuarios. Este proceso hoy es imposible en webs como Amazon o Trivago.

## VI. CONCLUSIONES

En este artículo se pone de manifiesto la necesidad de representar las opiniones de los usuarios de forma distinta a la utilizada por muchas plataformas web debido a su falta de expresividad en muchas ocasiones. El uso de aproximaciones borrosas puede ayudar a paliar estos defectos como se ha comentado a lo largo del artículo.

Seguindo el modelo propuesto, sería más fácil descartar opiniones que pueden no tener valor para un usuario, bien porque en sí pudieran ser contradictorias o de poco valor, o porque estuvieran emitidas por usuarios con el propósito de influir en otros usuarios de forma malintencionada.

## AGRADEMIENTOS

Este artículo ha sido financiado por FEDER y la Agencia Española de Investigaciones del Ministerio de Economía y Competitividad bajo el proyecto TIN2016-76843-C4-2-R (AEI/FEDER, UE).

## BIBLIOGRAFÍA

- [1] E. Cambria, B. Schuller, Y. Xia, and C. Havasi, "New Avenues in Opinion Mining and Sentiment Analysis," *IEEE Intell. Syst.*, vol. 28, no. 2, pp. 15–21, 2013.
- [2] A. Reyes, P. Rosso, and D. Buscaldi, "From humor recognition to irony detection: The figurative language of social media," *Data Knowl. Eng.*, vol. 74, pp. 1–12, 2012.
- [3] C. Zhang, D. Zeng, J. Li, F.-Y. Wang, and W. Zuo, "Sentiment analysis of Chinese documents: From sentence to document level," *J. Am. Soc. Inf. Sci. Technol.*, vol. 60, no. 12, pp. 2474–2487, 2009.
- [4] R. Moraes, F. Valiati, J. and W. P. Gavião Neto, "Document-level sentiment classification: An empirical comparison between SVM and ANN," *Expert Syst. Appl.*, vol. 40, no. 2, pp. 621–633, 2013.
- [5] A. Duric and F. Song, "Feature selection for sentiment analysis based on content and syntax models," *Decis. Support Syst.*, vol. 53, no. 4, pp. 704–711, 2012.
- [6] Y. He and D. Zhou, "Self-training from labeled features for sentiment analysis," *Inf. Process. Manag.*, vol. 47, no. 4, pp. 606–616, Jul. 2011.
- [7] T. Wilson, J. Wiebe, and P. Hoffmann, "Recognizing contextual polarity in phrase-level sentiment analysis," in *Proceedings of the conference on Human Language Technology and Empirical Methods in Natural Language Processing (HLT '05)*, 2005, pp. 347–354.
- [8] T. Wilson, J. Wiebe, and P. Hoffmann, "Recognizing Contextual Polarity: An Exploration of Features for Phrase-Level Sentiment Analysis," *Comput. Linguist.*, vol. 35, no. 3, pp. 399–433, 2009.
- [9] A. Agarwal, F. Biadys, and K. R. McKeown, "Contextual phrase-level polarity analysis using lexical affect scoring and syntactic N-grams," in *Proceedings of the 12th Conference of the European Chapter of the Association for Computational Linguistics (EACL '09)*, 2009, pp. 24–32.
- [10] R. Remus and C. Hähnig, "Towards well-grounded phrase-level polarity analysis," in *Proceedings of the 12th international conference on Computational linguistics and intelligent text processing (CICLing'11)*, 2011, pp. 380–392.
- [11] L.-C.- Yu, J.-L. Wu, P.-C. Chang, and H.-S. Chu, "Using a contextual entropy model to expand emotion words and their intensity for the sentiment classification of stock market news," *Knowledge-Based Syst.*, vol. 41, pp. 89–97, 2013.
- [12] Y. He, C. Lin, and H. Alani, "Automatically extracting polarity-bearing topics for cross-domain sentiment classification," in *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies (HLT '11)*, 2011, pp. 123–131.
- [13] M. Dragoni and G. Petrucci, "A fuzzy-based strategy for multi-domain sentiment analysis," *Int. J. Approx. Reason.*, vol. 93, pp. 59–73, 2018.
- [14] S. Raaijmakers and W. Kraaij, "A Shallow Approach to Subjectivity Classification," in *Proceedings of the Second International Conference on Weblogs and Social Media (ICWSM '08)*, 2008, pp. 216–217.
- [15] K. Sarvabhotla, P. Pingali, and V. Varma, "Sentiment classification: a lexical similarity based approach for extracting subjectivity in documents," *Inf. Retr. Boston.*, vol. 14, no. 3, pp. 337–353, 2011.
- [16] A. Montoyo, P. Martínez-Barco, and A. Balahur, "Subjectivity and sentiment analysis: An overview of the current state of the area and envisaged developments," *Decis. Support Syst.*, vol. 53, no. 4, pp. 675–679, 2012.
- [17] I. Maks and P. Vossen, "A lexicon model for deep sentiment analysis and opinion mining applications," *Decis. Support Syst.*, vol. 53, no. 4, pp. 680–688, 2012.
- [18] D. Wang, S. Zhu, and T. Li, "SumView: A Web-based engine for summarizing product reviews and customer opinions," *Expert Syst. Appl.*, vol. 40, no. 1, pp. 27–33, 2013.
- [19] K.-M. Park, H. Park, H.-G. Kim, and H. Ko, "Review summarization based on linguistic knowledge," in *Proceedings of the 17th international conference on Database Systems for Advanced Applications (DASFAA'12)*, 2012, vol. 7240, pp. 105–114.
- [20] K. Ganesan, C. Zhai, and E. Viegas, "Micropinion generation: An Unsupervised Approach to Generating Ultra-Concise Summaries of Opinions," in *Proceedings of the 21st international conference on World Wide Web - WWW '12*, 2012, pp. 869–878.
- [21] S.-W. Lee, Y.-I. Song, J.-T. Lee, K.-S. Han, and H.-C. Rim, "A new generative opinion retrieval model integrating multiple ranking factors," *J. Intell. Inf. Syst.*, vol. 38, no. 2, pp. 487–505, May 2011.
- [22] L. Guo and X. Wan, "Exploiting syntactic and semantic relationships between terms for opinion retrieval," *J. Am. Soc. Inf. Sci. Technol.*, vol. 63, no. 11, pp. 2269–2282, 2012.
- [23] E. Filatova, "Irony and Sarcasm: Corpus Generation and Analysis Using Crowdsourcing," in *Proceedings of the Eighth International Conference on Language Resources and Evaluation (LREC-2012)*, 2012, pp. 392–398.
- [24] A. Reyes and P. Rosso, "Making objective decisions from subjective data: Detecting irony in customer reviews," *Decis. Support Syst.*, vol. 53, no. 4, pp. 754–760, 2012.
- [25] J. Savoy, "Authorship Attribution Based on Specific Vocabulary," *ACM Trans. Inf. Syst.*, vol. 30, no. 2, pp. 1–30, 2012.
- [26] M. Montesi and T. Navarrete, "Classifying web genres in context: A case study documenting the web genres used by a software engineer," *Inf. Process. Manag.*, vol. 44, no. 4, pp. 1410–1430, 2008.
- [27] A. Mukherjee, B. Liu, and N. Glance, "Spotting fake reviewer groups in consumer reviews," in *Proceedings of the 21st international conference on World Wide Web (WWW '12)*, 2012, pp. 191–200.
- [28] S. Xie, G. Wang, S. Lin, and P. S. Yu, "Review spam detection via temporal pattern discovery," in *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2012, pp. 823–831.
- [29] G. Wang, S. Xie, B. Liu, and P. S. Yu, "Identify Online Store Review Spammers via Social Review Graph," *ACM Trans. Intell. Syst. Technol.*, vol. 3, no. 4, pp. 1–21, 2012.
- [30] K. Gutiérrez-Batista, J. R. Campaña, M.-A. Vila, and M. J. Martín-Bautista, "Fuzzy Analysis of Sentiment Terms for Topic Detection Process in Social Networks," in *International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*, 2018, pp. 3–14.
- [31] R. R. Yager, "Families of OWA operators," *Fuzzy Sets Syst.*, vol. 59, no. 2, pp. 125–148, 1993.
- [32] S.-M. Zhou, F. Chiclana, R. I. John, and J. M. Garibaldi, "Type-1 OWA operators for aggregating uncertain information with uncertain weights induced by type-2 linguistic quantifiers," *Fuzzy Sets Syst.*, vol. 159, no. 24, pp. 3281–3296, Dec. 2008.



# Engine health monitoring with fuzzy data: lessons learned from aircraft industry

Luciano Sánchez  
*Universidad de Oviedo*  
*Departamento de Informática*  
 Gijón, Asturias, Spain  
 luciano@uniovi.es

Inés Couso  
*Universidad de Oviedo*  
*Departamento de Estadística*  
 Gijón, Asturias, Spain  
 couso@uniovi.es

**Abstract**—The use of data-driven techniques for health monitoring and prognosis of engines is often plagued by the lack of information about failure scenarios. This problem is aggravated when there are missing or partially missing records in the log data. Unluckily, the chance that a sequence of events leading to a failure is not properly stored is higher when the system exhibits an abnormal behaviour. In absence of patterns that can be related to deterioration, failure detection is often guided to find novelties in the records, or uncommon combinations of variables that may indicate an anomalous performance. Finding novelties in sequences of low quality data is a complex problem where numerous ambiguities must be resolved. Aircraft industry is a paradigmatic case in that it involves monitoring and prognosis with less than perfect data, partly because many different control and security subsystems prevent that failure conditions are actually reached. The use of fuzzy technologies for modelling and diagnosing aero-engines is discussed in this paper, along with the most challenging issues and future research lines, according to our own experience in this field.

**Index Terms**—Fuzzy data, Engine health monitoring, Fault diagnosis, Fuzzy model

## I. INTRODUCTION

The main purpose of engine data is to monitor engine parameters in order to avoid running the engine under undesired conditions. Engine instrumentation is configured to trigger alerts related to operator action, maintenance action or, if a significant condition is found, shutting down the engine.

The development over time of the engine data is also monitored in a process that is called Engine Health Monitoring (EHM). EHM management systems have diagnostic and prognostic purposes, as not only individual working conditions but also the trend over time are examined in order to identify rapid levels of deterioration. EHM management systems estimate the Remaining Useful Life (RUL) of an engine, anticipating certain events or findings and therefore reducing the number and degree of engine refurbishments [1]. In the simplest case, EHM management systems compare engine data against those parameters identified to be characteristic of known engine conditions or against design limits [2]. However, predicting the engine parameter deterioration levels over time is complex. There are multiple methods of EHM data assessment

developed, whose range of application depends on the type of engine and the amount and quality of the engine data.

This study concerns the application of fuzzy technologies for EHM in aircrafts, where multi-sensor information is used to report failures and predict the RUL of commercial turbofan engines. Aircraft industry has specific requirements for EHM systems, derived from the fact that gas turbines are inherently fail-safe and the reliability of the turbine may be higher than that of its sensors [3]. Sensor degradation cannot be tolerated because deviations in sensor readings can be mistaken for engine degradations and this can cause secondary failures because of wrong control decisions [4]. Hence, aircraft engines tend to be under-sensorized and a substantial uncertainty in the knowledge of the operating point of the engine is accepted. Uncertainty in EHM data is accounted for via mathematical models, statistical or intelligent techniques, and in many cases with the help of fuzzy technologies, which will be reviewed in the forthcoming sections.

The structure of this paper is as follows: Section II reviews the use of fuzzy technologies in aircraft EHM, discusses the strengths and weaknesses of these techniques, and states some open problems. A new family of fuzzy diagnostic tools is proposed in Section III. An explanatory application of the new tools is developed in Section IV. The conclusions of the paper are presented in Section V.

## II. REVIEW OF THE USE OF FUZZY TECHNOLOGIES IN AEROENGINE HEALTH MONITORING

Most of the aircraft EHM assessment methods are based around Gas Path Analysis (GPA) [2]. The gas path components are all air-washed parts within the engine gas path: the compressors, the combustor and the turbines. The gas path components are susceptible to distinct different issues, such as worn seals, excessive tip clearances, burning, cracking or missing parts or sections of parts, etc. Changes in the internal working conditions of the engine are detected either by direct observation of EHM parameters or indirectly, through a suitable transform of the EHM data.

This work was supported by the Science and Innovation Spanish Ministry under Projects TIN2014-56967-R and TIN2017-84804-R

#### A. Direct methods: detection of novelties with pattern recognition

The most common GPA methodology consists in detecting changes or *novelties* [5] in the internal working conditions of the engine as early as possible, by finding specific combination of values or *signatures* of the different defects. Fuzzy expert systems have been used to identify engine trends and step changes [6]. These algorithms rely on an experience database comprising GPA variables sampled at engines with known faults. Recent approaches learn fuzzy models from clean engine data and deteriorations are detected as novelties in the EHM data or in the residuals between the measurements and the model predictions [7], [8].

The diagnosis of an engine is formulated as a supervised pattern recognition problem, often via a case-based reasoning algorithm in which the measurements are compared to the known signatures of defects that have been observed in the past [9]. Thus, pattern recognition techniques are only efficient if the experience database is complete; otherwise, unseen defects will remain undetected. This is a requirement hard to fulfil, as most of times the Full Authority Digital Engine Control (FADEC) and other safety mechanisms will prevent that the engine reaches these abnormal conditions. Also, there are faults that do not have a well defined signature: for instance, a higher than normal turbine temperature may have different causes, such as an incipient deterioration or a higher load of the engine. Pattern recognition cannot tell apart these root causes if temperature, fuel flow, pressures and thrust are treated in isolation.

#### B. Subspace methods and manifold learning

Since most of the deteriorations alter more than one GPA variable, some authors consider that each of these variables must be regarded as a mix of different factors [10]. In this respect, subspace methods project EHM variables into a low-dimensional factor space and the signatures of the defects are sought in this projection [11], [12]. In other cases, a non-linear transformation is used; for instance, neural-network based autoencoders condense the EHM information into a reduced number of variables [13]. Recently, other manifold learning techniques have been extended to uncertain data and applied to this problem. In [14], Blind Source Separation (BSS) for interval-valued data data has been applied to the EHM problem thus the independence among the factor is maximized. This last reference addresses the presence of epistemic uncertainty in the data. In any case, note that although the dimensionality reduction simplifies the aforementioned pattern recognition problem, the need for an experience database is still present.

#### C. Multivariate trend analysis of delta signals

One of the major sources of uncertainty in EHM is related to the scarcity of sensors. Measurements are taken under different flying conditions. Hence, certain changes in the monitored variables may be caused by either a deterioration in the engine or a change in the flight conditions. Furthermore, there is a wide variability between GPA related magnitudes for different

engines, as the monitored variables of two engines flying in the same conditions might not be concordant from flight to flight. Following [15], this second variability is solved if defects are not sought in GPA variables but in the gradient of the so-called “delta” functions, which are the differences between GPA variables and the theoretical values of a single reference engine. The gradient of these delta functions are used, because useful information about the deterioration speed is conveyed by the slopes of these curves. However, since GPA variables combine measurements taken in different flying conditions, delta signals are very noisy. This poses a complex computational problem, as determining the gradient of a noisy signal is strongly dependent on the properties of the noise filter. A fuzzy-bandwidth filter was used to compute these slopes in [16], where a fuzzy rule-based classifier was subsequently used to monitor the engine on the basis of the multivariate gradient signal, and also in [17] fuzzy estimations of the RULs of compressor and turbine were produced for prognosis purposes. These methods still make use of a sample of engines with a known condition, that is used for learning classifier and RUL models. In contrast, the experience database with the signatures of the known defects are not needed anymore, as the monitoring and prognosis decisions are taken by data-driven fuzzy rule-based systems.

#### D. Sequence mining

Multivariate trend analysis transforms variable-length series of gradients into fixed-length feature vectors that are the inputs to a fuzzy classifier or model. This feature selection process discards the sequence order of the deteriorations. For example, suppose that two different motors #1 and #2 have bad compressors and turbines: the compressor of #1 failed first and its turbine was subsequently damaged because of the compressor bad state. In contrast, the turbine in #2 failed first and its compressor was damaged later. It may happen that their feature vectors in trend analysis are identical. In reference [18] the fixed-length transform is avoided, and specific sequential pattern mining-based classifiers (that can operate with variable-length fuzzy inputs) were leveraged. Sequence mining discovers conditions that are not to be found with multivariate trend analysis. In any case, other drawbacks exist: a sample of engines with known conditions is needed (although in this case the decision system does not require an experience database). Furthermore, frequent pattern matching techniques are used for identifying the signatures of the defects. Hence, isolated deteriorations will not be found.

Summarizing, the conclusions of this review in fuzzy EHM for aircrafts are:

- Direct methods operate with experience databases comprising GPA values of engines with known deteriorations. These methods are sensible to uncertainties originated in the variability from engine to engine, the changing flight conditions and the lack of sensors.
- Fuzzy subspace methods alleviate the uncertainty caused by the lack of sensors, as different imprecise signals are



combined to extract independent factors. The experience database is still needed.

- Multivariate trend analysis relax the requisite of an experience database to a list of engines with known RULs, thus not-yet-seen defects can be discovered. These methods cannot detect the precise time when a defect appeared.
- Sequence mining cannot find defects with a low occurrence, because the signatures are obtained via fuzzy frequent pattern matching.

### III. ISOTONIC FUZZY HEALTH MODELS

Diagnosis and prognosis methodologies either depend on an experience database, a sample of engines with known RULs or a model of the engine whose residual can be monitored. The main advantage of model-dependent assessments lies in the possibility of finding defects not seen before, but being dependent on an engine model is a stringent requisite. In this section a new isotonic fuzzy health model of an aeroengine is proposed, whose residual can be related to the location of the deteriorations. This method is novel because it makes use of *the lowest possible amount of domain knowledge*, which is (i) certain variables in the engine are comonotonic, and (ii) the state of health of the engine decreases with time.

The input variables of the proposed model are the same “delta” variables introduced in Section II-C. In the particular case of the aeroengines concerned by this study (see Figure 1), these variables are called  $\Delta P30, \Delta T30, \Delta TGT, \Delta FF$  and  $\Delta N2$ . The list of points of interest in the engine are:

- Station 3: This is the High Pressure Compressor (HPC) exit and the entry into the combustion system. The conditions at this point are key for the correct functioning of the engine. The main variables measured at this station are P30 (pressure) and T30 (temperature).
- Station 4: This is the combustion chamber exit and High Pressure Turbine (HPT) entry. The temperature at this point is one of the main engine parameters. T4, may also be known as Turbine Gas Temperature (TGT)
- Station 5: This is the Low Pressure Turbine (LPT) exit. The main variable at this station is P50. This pressure is used to define EPR, which is subsequently used to determine the overall engine thrust. EPR is the relation of P50 to P20.

The Low Pressure (LP) system is the combination of the fan and the LPT. The speed at which the LP system turns is defined as N1. The High Pressure (HP) system is the combination of the HPC and the HPT. The speed at which the HP system turns is known as N2. In addition, the amount of fuel consumed is also monitored through Fuel Flow (FF).

EPR is the relation of P50 (pressure at the Low Pressure Turbine exit) to P20 (pressure at the fan inlet). In two shaft high bypass ratio turbo fans, the thrust is performed by the air compressed by the fan blades and pushed through the engine bypass. The air pushed through the core of the engine is solely used to turn the fan. This is, the air is compressed by the high pressure compressor (HPC) so that the optimum conditions are

reached within the combustion chamber to subsequently turn the high pressure turbine (HPT) to maintain the high pressure (HP) system and subsequently turn the low pressure turbine (LPT) which moves the fan and produces the engine thrust.

#### A. Proposed isotonic fuzzy model

Let the thrust of the considered engine be described by the following function:

$$\text{epr}(\Delta P30, \Delta T30, \Delta TGT, \Delta FF, \Delta N2, \mathbf{fc}) \quad (1)$$

where  $\mathbf{fc} \in \text{FC}$  is a vector defining the flight conditions,  $\Delta P30$  is the difference between the gas pressure at the entry of the HPC and that of the reference engine, etc. Note that the thrust of the reference motor is  $\text{epr}_0(0, 0, 0, 0, 0, \mathbf{fc})$ . For engines that are in a good condition,

- $\text{epr}(\cdot)$  is comonotonical with  $\Delta P30, \Delta FF, \Delta TGT, \Delta N2$  (the higher the compressor pressure, the consumed fuel, the turbine temperature and the turbine speed, then the higher the thrust is)
- $\text{epr}(\cdot)$  is antimonotonical with  $\Delta T30$  (the higher the compressor temperature, the less dense the air is, hence the thrust is lower)

Thus, the following fuzzy-valued model is proposed:

$$\mu_{\overline{\text{EPR}}}(\Delta P30, \Delta T30, \Delta TGT, \Delta FF, \Delta N2)(e) = \sup_{\alpha} \{e \in [\overline{\text{EPR}}]_{\alpha}(\Delta P30, \Delta T30, \Delta TGT, \Delta FF, \Delta N2)\} \quad (2)$$

where the set  $[\overline{\text{EPR}}]_{\alpha}$  is a confidence interval of the thrusts of the engine,

$$[\overline{\text{EPR}}]_{\alpha} = \{\text{epr}_i(\Delta P30, \Delta T30, \Delta TGT, \Delta FF, \Delta N2, \mathbf{fc}) : \mathbf{fc} \in \text{FC}_{\alpha}\} \quad (3)$$

and  $\text{FC}_{\alpha}$  is the smallest subset of  $\text{FC}$  such that  $P(\mathbf{fc} \in \text{FC}) \geq 1 - \alpha$  and  $\text{FC}_{\alpha} \subseteq \text{FC}_{\beta}$  for  $\alpha > \beta$ . Lastly, let the parametric definition of  $\text{epr}(\cdot)$  be

$$\text{epr}(\Delta P30, \Delta T30, \Delta TGT, \Delta FF, \Delta N2, \mathbf{fc}) = f(\kappa_1 \cdot \Delta P30 - \kappa_2 \cdot \Delta T30 + \kappa_3 \cdot \Delta TGT + \kappa_4 \cdot \Delta FF + \kappa_5 \cdot \Delta N2) + g(\mathbf{fc}) \quad (4)$$

and

$$[\overline{\text{EPR}}]_{\alpha}(\Delta P30, \Delta T30, \Delta TGT, \Delta FF, \Delta N2) = f(\kappa_1 \cdot \Delta P30 - \kappa_2 \cdot \Delta T30 + \kappa_3 \cdot \Delta TGT + \kappa_4 \cdot \Delta FF + \kappa_5 \cdot \Delta N2) + [\gamma - \mu(1 - \alpha), \gamma + \mu(1 - \alpha)] \quad (5)$$

with  $\kappa_i \geq 0, g(\mathbf{fc}) \geq 0$  for all  $\mathbf{fc} \in \text{FC}$  and  $f(x) \geq f(y)$  for  $x > y$ .

It can be safely assumed that engines are without defects in the first cycles after a shop visit, and  $\kappa_1, \dots, \kappa_5$  and  $\gamma, \mu$  can be found by maximizing the interval-valued extension of Kendall's tau [19] between  $[\overline{\text{EPR}}]_{\alpha}$  and the actual thrust values

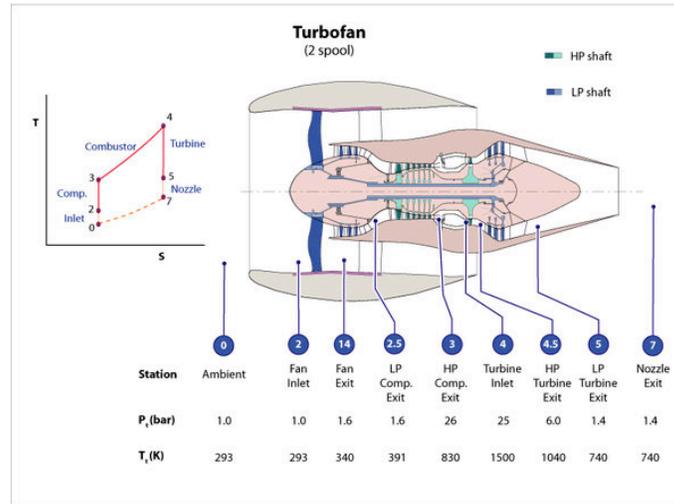


Fig. 1. Outline of a two shaft high bypass ratio turbo fan

$EPR^t$  of the engine at the first  $t = 1 \dots N$  cycles, constrained by  $\kappa_i \geq 0$ ,  $\gamma > 0$ ,  $\mu > 0$  and

$$\#\{EPR^t \in [\overline{EPR}]_\alpha(\Delta P30^t, \Delta T30^t, \Delta TGT^t, \Delta FF^t, \Delta N2^t)\} \geq (1 - \alpha) \cdot N \quad (6)$$

The expression of the function  $f$  is obtained by interpolating the pairs  $(\kappa_1 \cdot \Delta P30^t - \kappa_2 \cdot \Delta T30^t + \kappa_3 \cdot \Delta TGT^t + \kappa_4 \cdot \Delta FF^t + \kappa_5 \cdot \Delta N2^t + \gamma, EPR^t)$  with a Piecewise Cubic Hermite Interpolating Polynomial (PCHIP).

Lastly, once the membership function of the fuzzy model is known,

$$\mu_{\widetilde{EPR}^t}(e) = \mu_{\widetilde{EPR}}(\Delta P30^t, \Delta T30^t, \Delta TGT^t, \Delta FF^t, \Delta N2^t)(e) \quad (7)$$

the residuals of this model can be regarded as a health indicator, as will be shown in an illustrative example in the next Section:

$$\mu_{\widetilde{HEALTH}^t}(e) = \mu_{\widetilde{EPR}^t}(e - EPR^t). \quad (8)$$

In words, the residuals of the proposed model will be centered at zero if the engine is not deteriorated, but as soon as a degradation happens (decrease of  $\Delta P30$ , alone or in combination of an increase of  $\Delta T30$ ,  $\Delta TGT$ , etc.) the predicted thrust will be lower than that of the non-degraded engine, because of the signs of the coefficients and the monotonicity of the function  $f$ . Given that the health of an engine cannot be increased unless it undergoes maintainance, isotonic regression techniques are also used to estimate the centerpoints of the aforementioned residuals.

#### IV. ILLUSTRATIVE EXAMPLE

The new method has been validated on a sample of 330 turbofan engines. A representative case has been chosen that illustrates the properties of this method.

Figure 2 depicts the GPA delta variables of an engine with a light deterioration in the HPT that cannot be found with direct methods, manifold learning, trend analysis neither sequence mining. A sixth variable DN2VIB has been added to the graph; this variable is not being used by the model but serves for validation purposes.

The isotonic fuzzy model has been fitted to the first  $N = 1000$  cycles. The whole data spans more than 4000 cycles. Each GPA value is colored according to the EPR (between 1.20 and 1.50). The synthetic HEALTH signal is obtained by fitting a line with isotonic regression to the centerpoints of the residual of the fuzzy model proposed in the preceding section. Observe that the health tends to increase in the first half of the monitored period, but the isotonic regression forces that the signal is monotonically decreasing. Hence, the HEALTH signal is constant in the initial cycles. In the second part of the diagnostic, the residual is decreased and a deterioration in the second half of the figure becomes evident. This signal has been built without supplying the model any kind of information about the signature of a degradation in a similar engine: the only domain knowledge is the monotonicity or antimonotonicity of the GPA delta signals and the thrust. As an additional validation of the method, note that the signal DN2VIB measures the vibrations in the high speed shaft. This information has not been used by the isotonic model, that was nonetheless able to detect a deterioration immediately before the vibrations were measurable.

#### V. CONCLUDING REMARKS AND FUTURE WORK

Most of times, fault detection are regarded as pattern recognition methods, that can be solved with data-driven techniques with a different amount of domain knowledge. If a large database of engines with different degrees of deterioration is available, direct and subspace methods are the most common fuzzy techniques, however these cannot detect defects that are not in the experience database.

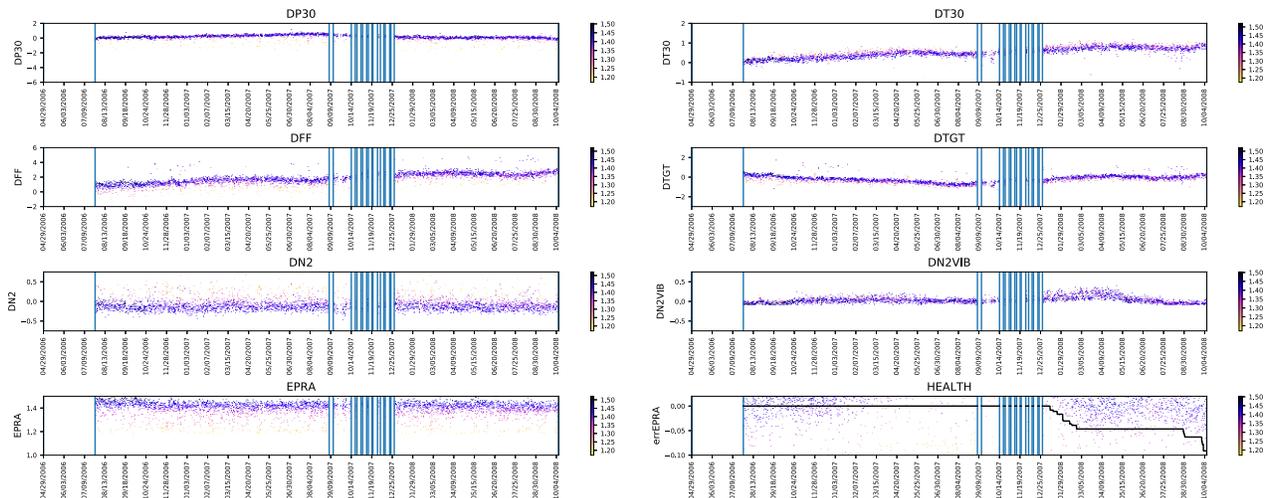


Fig. 2. Example of the application of the isotonic fuzzy model to an actual aeroengine. From left to right, top to bottom: Deltas of P30, T30, FF, TGT, N2, N2VIB (vibrations of the engine, not contemplated in this model) and synthetic HEALTH signal formed by the centerpoints of the isotonic fuzzy model. Observe that the model detects a deterioration of the engine in the last cycles, and this prediction is consistent with the independently measured vibration N2VIB.

The use of delta variables with respect to a reference engine allows applying machine learning algorithms to learn an EHM management system from data, where fuzzy technologies are used for designing the noise filters. The main drawbacks of these methods are the impossibility of detecting the order of the events and the precise cycle when the deterioration initiates. The use of sequence mining solves the first issue, and the isotonic algorithm introduced in this study solves the second problem. Besides its simplicity, the use of a model with a minimal amount of domain knowledge reduces the systematic error of specific models, and at the same time its generalization capabilities improve that of black boxes.

This is a work in progress; there are some aspects of the application of isotonic learning to EHM monitoring that are still unsolved. In particular, it is not yet clear how to attribute the descent in the thrust to the turbine or the compressor. Once this issue is solved, the next step in this research will be to assess the dependence between the RUL of the engine and the jumps in the health signal.

## REFERENCES

- [1] Y. Li, "Gas turbine performance and health status estimation using adaptive gas path analysis," *Journal of Engineering for Gas Turbines and Power*, vol. 132, no. 4, p. 041701, 2010.
- [2] L. A. Urban, "Gas Path Analysis Applied to Turbine Engine Condition Monitoring," *Journal of Aircraft*, vol. 10, no. 7, 2012.
- [3] A. R. Behbahani, "Need for robust sensors for inherently fail-safe gas turbine," in *52nd International Instrumentation Symposium: Engine Controls, Monitoring, and Prognostics*. Cleveland, OH, 2006.
- [4] ATSB, "Australian transport safety bureau: Power plant failures in turboprop-powered aircraft 2012 to 2016," <https://www.atsb.gov.au/publications/2017/ar-2017-017/>, accessed: 2018-06-06.
- [5] M. A. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko, "A review of novelty detection," *Signal Processing*, vol. 99, pp. 215–249, 2014.
- [6] S. Demirci, C. Hajiyev, and A. Schwenke, "Fuzzy logic-based automated engine health monitoring for commercial aircraft," *Aircraft Engineering and Aerospace Technology*, vol. 80, no. 5, pp. 516–525, 2008.
- [7] A. Benyounes, A. Hafaifa, A. Kouzou, and M. Guemana, "Gas turbine modeling using adaptive fuzzy neural network approach based on measured data classification," *Mathematics-in-Industry Case Studies*, vol. 7, no. 4, 2017.
- [8] Z. Li, S.-S. Zhong, and L. Lin, "Novel gas turbine fault diagnosis method based on performance deviation model," *Journal of Propulsion and Power*, pp. 1–10, 2016.
- [9] C. H. Fontes and O. Pereira, "Pattern recognition in multivariate time series—a case study applied to fault detection in a gas turbine," *Engineering Applications of Artificial Intelligence*, vol. 49, pp. 10–18, 2016.
- [10] Z. Chen, H. Fang, and Y. Chang, "Weighted data-driven fault detection and isolation: A subspace-based approach and algorithms," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 5, pp. 3290–3298, 2016.
- [11] R. Baklouti, M. Mansouri, M. Nounou, H. Nounou, and A. B. Hamida, "Iterated robust kernel fuzzy principal component analysis and application to fault detection," *Journal of Computational Science*, vol. 15, pp. 34–49, 2016.



- [12] I. Gueddi, O. Nasri, K. Benothman, and P. Dague, "Fault detection and isolation of spacecraft thrusters using an extended principal component analysis to interval data," *International Journal of Control, Automation and Systems*, vol. 15, no. 2, pp. 776–789, 2017.
- [13] W. Yan and L. Yu, "On accurate and reliable anomaly detection for gas turbine combustors: A deep learning approach," in *Proceedings of the Annual Conference of the Prognostics and Health Management Society*, 2015.
- [14] A. Martínez, L. Sanchez, and I. Couso, "Interval-valued blind source separation applied to ai-based prognostic fault detection of aircraft engines," *Journal of Multiple-Valued Logic & Soft Computing*, vol. 22, 2014.
- [15] A. Volponi and B. Wood, "Engine health management for aircraft propulsion systems," in *Proceedings of the Forum on Integrated System Health Engineering and Management (ISHEM) in Aerospace, Napa, CA, November, 2005*, pp. 7–10.
- [16] A. Martínez, L. Sánchez, and I. Couso, "Engine health monitoring for engine fleets using fuzzy radviz," in *Fuzzy Systems (FUZZ), 2013 IEEE International Conference on*. IEEE, 2013, pp. 1–8.
- [17] A. Martinez, L. Sánchez, and I. Couso, "Aeroengine prognosis through genetic distal learning applied to uncertain engine health monitoring data," in *Fuzzy Systems (FUZZ-IEEE), 2014 IEEE International Conference on*. IEEE, 2014, pp. 1945–1952.
- [18] A. Palacios, A. Martínez, L. Sánchez, and I. Couso, "Sequential pattern mining applied to aeroengine condition monitoring with uncertain health data," *Engineering Applications of Artificial Intelligence*, vol. 44, pp. 10–24, 2015.
- [19] O. Hryniewicz and K. Opara, "Efficient calculation of kendall's tau for interval data," in *Synergies of Soft Computing and Statistics for Intelligent Data Analysis*. Springer, 2013, pp. 203–210.



# Análisis de distintas propuestas de sistemas de recomendaciones lingüísticos difusos para personalizar información en bibliotecas digitales

Carlos Porcel  
dept. Informática  
Universidad de Jaén  
Jaén, Spain  
cporcel@ujaen.es

Alberto Ching-López  
dept. Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, Spain  
alch@decsai.ugr.es

Álvaro Tejada-Lorente  
dept. Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, Spain  
atejada@decsai.ugr.es

Juan Bernabé-Moreno  
dept. Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, Spain  
jbernabemoreno@gmail.com

Enrique Herrera-Viedma  
dept. Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, Spain  
viedma@decsai.ugr.es

Francisco Javier Cabrerizo  
dept. Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, Spain  
cabrerizo@decsai.ugr.es

Sergio Alonso  
dept. Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, Spain  
zetjioi@ugr.es

Los grandes avances que se están produciendo en los últimos años en lo que respecta a las tecnologías de la información y las telecomunicaciones, está cambiando la forma en la que accedemos a la información. Internet es la principal fuente de información y por tanto, está afectando al desarrollo del resto de medios. Tal es el caso de las bibliotecas digitales, que tienen que hacer frente a nuevos problemas provocados por el gran crecimiento de contenido digital y aplicaciones basadas en Web [2]. Efectivamente, los usuarios tienen serias dificultades a la hora de acceder a la información deseada de forma sencilla y en el momento oportuno. Es lo que se conoce como problema de sobrecarga de información. El uso de herramientas automáticas ayuda a afrontar y gestionar la gran cantidad de información disponible online en formato digital. También ayuda al personal de la biblioteca en la difusión de información de forma personalizada [1], [2].

Entonces, las herramientas a usar en bibliotecas digitales deben adoptar un papel más activo y ofrecer a los usuarios nuevos servicios que faciliten el acceso y personalización de la información, facilitando además, el que puedan compartir conocimiento. En este sentido, sería muy interesante que las bibliotecas digitales puedan anticipar las necesidades y preferencias de los usuarios, para suministrarles recursos que sean de su interés, incluso aunque no supieran de sus existencia. Pero debido al problema de sobrecarga de información que antes comentábamos, encontramos serias dificultades para conseguir ese objetivo.

Para ello, planteamos el uso de sistemas de recomendaciones,

que han demostrado su utilidad en numerosos entornos, para facilitar y personalizar el acceso a la información [1]. Un sistema de recomendaciones ayuda a los usuarios a descubrir información de interés y de forma personalizada. Por ello, son especialmente útiles para facilitar a los usuarios el acceso a recursos que antes no conocían. Una de las claves del éxito de estos sistemas es que consiguen una correcta personalización en el sentido en que tratan a cada usuario de forma distinta. Para ello, el sistema debe contar con algún tipo de información sobre los usuarios, como por ejemplo, las valoraciones sobre los recursos que hayan explorado con anterioridad. Con ello, el sistema establece y gestiona sus perfiles, donde quedan representadas las preferencias y necesidades de cada uno. Y hay distintas formas de adquirir ese conocimiento, pudiendo hacerse de forma implícita (es decir, sin interacción con el usuario) o solicitando que los usuarios expresen sus preferencias de forma explícita.

En este trabajo, versión resumida del trabajo publicado en [3], analizamos distintas propuestas de aplicación de técnicas de recomendación para favorecer la difusión de información en bibliotecas digitales. Pero, dada la gran variedad de formas de representar y evaluar la información cuando los usuarios intervienen (como es el caso que nos ocupa), nos centramos en propuestas basadas en lógica difusa. En concreto, analizamos cuatro propuestas que incorporan el modelado lingüístico difuso multigranular:

1. La primera propone un sistema de recomendaciones

lingüístico difuso que sugiere tanto recursos especializados según el área de interés de cada usuario, como recursos complementarios que podrían ser interesantes para ayudar en la formación de grupos multidisciplinares [6].

2. La segunda presenta un nuevo método para obtener información sobre las preferencias de los usuarios, reduciendo de esta manera el gran esfuerzo que tenían que realizar en propuestas previas y favoreciendo, por tanto, la adquisición de perfiles de usuarios. Los usuarios proporcionan sus preferencias sobre los principales recursos de investigación, usando relaciones de preferencia lingüísticas difusas incompletas. A partir de esta información el sistema construye sus respectivos vectores de preferencias sobre los distintos temas de interés y con ello, genera las recomendaciones [4].
3. En el tercer caso, se plantea una mejora de las propuestas anteriores, basándose en la incorporación de una memoria que ayude a paliar el problema de sobrecarga de información, aún persistente en bibliotecas digitales. La idea consiste en tener en cuenta las preferencias de los usuarios en cuanto al número de recomendaciones de recursos que quieren recibir, y entonces, usar recursos previamente seleccionados aunque no recomendados (por dichas restricciones de cantidad) para formar una nueva selección de recursos en nuevas rondas de recomendación [5].
4. La idea principal desarrollada en la última de las propuestas analizadas, consiste en considerar el proceso de generación de recomendaciones como una tarea con dos elementos distintos. Se trata de encontrar, por un lado, recursos de investigación que sean relevantes para los usuarios, pero por otro lado, encontrar recursos que sean válidos desde el punto de vista de la calidad de los mismos. Entonces, se hace una estimación tanto de la relevancia de los recursos como de su calidad, y ambos valores, se agregan en una nueva métrica que se tiene en cuenta para recomendar o no un recurso [7].

En todo este panorama, vemos que efectivamente en los últimos años se han ido consiguiendo bastantes logros gracias a la aplicación y rápido avance de las tecnologías de la información y las comunicaciones. Se puede destacar la posibilidad de trabajar con enormes cantidades de información, y no sólo con información basada en texto, sino incluyendo imágenes, audio, vídeo y material multimedia. Pero es crucial, no sólo trabajar con esas cantidades y distintos formatos de información, sino hacerlo de forma personalizada. Hasta ahora se han venido aplicando numerosas técnicas pero en determinadas ocasiones son los propios usuarios los que deben gestionar la información de forma explícita [6]. En este contexto, podría ayudar la aplicación de técnicas de aprendizaje automático que posibiliten automatizar la construcción de modelos de usuarios. También se han hecho algunos avances en este sentido [4], [5], [7], pero a pesar de los logros conseguidos, su principal limitación es la necesidad de interactuar con el

personal de la biblioteca para establecer las representaciones internas de los recursos. Por ello, encontramos en este punto un reto significativo al que se deberá hacer frente, así como seguir adaptándose a las nuevas casuísticas de la sociedad actual, como puede ser el auge experimentado en el uso de redes sociales.

Como conclusión, creemos que a pesar de los grandes avances llevados a cabo, las oportunidades y retos para las futuras bibliotecas digitales pasan por esta triple perspectiva:

- Dado que la información generada de forma electrónica continúa creciendo y se prevé un crecimiento aún mayor, habrá que hacer frente a ello con nuevas herramientas o técnicas. La idea es que favorezcan la personalización de los servicios y la difusión de información de forma personalizada, por lo que habría que seguir mejorando en el establecimiento automático de los perfiles de usuarios y en el estudio y aplicación de técnicas automáticas que permitan obtener la representación interna de los recursos.
- Considerar el entorno social de los usuarios. La idea sería explotar información diversa extraída de los distintos medios sociales en los que participan los usuarios, lo que permitiría ayudar a la construcción automática de perfiles de usuarios.
- Proponer e implantar sistemas reales que faciliten las labores de difusión de información en bibliotecas digitales, y que con su uso lo más extendido posible, permitan obtener datos suficientes que faciliten la evaluación de las distintas propuestas que puedan ir surgiendo.

#### AGRADECIMIENTOS

Este trabajo ha sido desarrollado gracias a la financiación FEDER del Proyecto TIN2016-75850-R.

#### REFERENCIAS

- [1] M. Franke, A. Geyer-Schulz, and A. Neumann, "Recommender services in scientific digital libraries", in *Multimedia Services in Intelligent Environments*. Heidelberg: Springer, pp. 377-417, 2008.
- [2] R. D. Montoya, "Boundary objects/boundary staff: supporting digital scholarship in academic libraries", *Journal of Academic Librarianship*, vol. 43(3), pp. 216-223, 2017.
- [3] C. Porcel, A. Ching-López, J. Bernabé-Moreno, A. Tejada-Lorente, and E. Herrera-Viedma, "Fuzzy Linguistic Recommender Systems for the Selective Diffusion of Information in Digital Libraries", *J. Inf. Process Syst.*, Vol.13(4), pp. 653-667, 2017.
- [4] C. Porcel, and E. Herrera-Viedma, "Dealing with Incomplete Information in a Fuzzy Linguistic Recommender System to Disseminate Information in University Digital Libraries", *Knowledge-Based Systems*, vol. 23, pp. 32-39, 2010.
- [5] C. Porcel, J.M. Morales-del-Castillo, M.J. Cobo, A.A. Ruíz, and E. Herrera-Viedma, "An Improved Recommender System to Avoid the Persistent Information Overload in a University Digital Library", *Control and Cybernetics-ICAE Journal Special Issue*, vol. 39(4), pp. 899-924, 2010.
- [6] C. Porcel, J.M. Moreno, and E. Herrera-Viedma, "A Multi-Disciplinary Recommender System to Advice Research Resources in University Digital Libraries", *Expert Systems with Applications*, vol. 36(10), pp. 12520-12528, 2009.
- [7] A. Tejada-Lorente, C. Porcel, E. Peis, R. Sanz, and E. Herrera-Viedma, "A quality based recommender system to disseminate information in a University Digital Library", *Information Science*, vol. 261, pp.52-69, 2014.

**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 8:  
FUNDAMENTOS DE  
LÓGICA FUZZY







# Equivalence relations on fuzzy subgroups\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

C. Bejines, M.J. Chasco, J. Elorza

*Universidad de Navarra*

Pamplona, Spain

cbejines@alumni.unav.es, {mjchasco,jelorza}@unav.es

S. Montes

*Universidad de Oviedo*

Oviedo, Spain

montes@uniovi.es

**Abstract**—We compare four equivalence relations defined in fuzzy subgroups: Isomorphism, fuzzy isomorphism and two equivalence relations defined using level subset notion. We study if the image of two equivalent fuzzy subgroups through aggregation functions is a fuzzy subgroup, when it belongs to the same class of equivalence and if the supreme property is preserved in the class of equivalence and through aggregation functions.

**Index Terms**—Aggregation function, fuzzy subgroup, level subgroup, isomorphism, fuzzy isomorphism, sup property

# An alternative axiomatization for a fuzzy modal logic of preferences

Amanda Vidal  
ICS - Czech Academy of Sciences  
Prague, Czech Republic  
amanda@cs.cas.cz

Francesc Esteva  
IIIA - CSIC  
Bellaterra, Spain  
esteva@iiia.csic.es

Lluís Godo  
IIIA - CSIC  
Bellaterra, Spain  
godo@iiia.csic.es

**Abstract**—In a recent paper, the authors have proposed an axiomatic system for a modal logic of gradual preference on fuzzy propositions that was claimed to be complete with respect to the intended semantics. Unfortunately, the completeness proof has a flaw, that leaves still open the question of whether the proposed system is actually complete. In this paper, we propose an alternative axiomatic system with a multi-modal language, where the original modal operators are definable and their semantics are preserved, and for which completeness results are proved.

**Index Terms**—fuzzy preferences, fuzzy modal logic, completeness

## I. INTRODUCTION

Reasoning about preferences is a topic that has received a lot of attention in Artificial Intelligence since many years, see for instance [HGY12], [DHKP11], [Kac11]. Two main approaches to representing and handling preferences have been developed: the relational and the logic-based approaches.

In the classical setting, every preorder (i.e. reflexive and transitive) relation  $R \subseteq W \times W$  on a set of alternatives  $W$  can be regarded as a (weak) preference relation by understanding  $(a, b) \in R$  as denoting *b is not less preferred than a*. From  $R$  one can define three disjoint relations:

- the *strict preference*  $P = R \cap R^d$ ,
- the *indifference relation*  $I = R \cap R^t$ , and
- the *incomparability relation*  $J = R^c \cap R^d$ .

where  $R^d = \{(a, b) \in R : (b, a) \notin R\}$ ,  $R^t = \{(a, b) : (b, a) \in R\}$  and  $R^c = \{(a, b) \in R : (a, b) \notin R\}$ . It is clear that  $P$  is a strict order (irreflexive, antisymmetric and transitive),  $I$  is an equivalence relation (reflexive, symmetric and transitive) and  $J$  is irreflexive and symmetric. The triple  $(P, I, J)$  is called a *preference structure*, where the initial weak preference relation can be recovered as  $R = P \cup I$ .

In the fuzzy setting, preference relations can be attached degrees (usually belonging to the unit interval  $[0, 1]$ ) of fulfilment or strength, so they become *fuzzy relations*. A weak fuzzy preference relation on a set  $X$  will be now a fuzzy preorder  $R : X \times X \rightarrow [0, 1]$ , where  $R(a, b)$  is interpreted as the degree

in which  $b$  is at least as preferred as  $a$ . Given a t-norm  $\odot$ , a fuzzy  $\odot$ -preorder satisfies reflexivity ( $R(a, a) = 1$  for each  $a \in X$ ) and  $\odot$ -transitivity ( $R(a, b) \odot R(b, c) \leq R(a, c)$  for each  $a, b, c \in X$ ). The most influential reference is the book by Fodor and Roubens [FR94], that was followed by many other works like, for example [DBM07], [DBM10], [DMB04], [DBM08], [DGLM08]. In this setting, many questions have been discussed, like e.g. the definition of the strict fuzzy order associated to a fuzzy preorder (see for example [Bod08a], [Bod08b], [BD08], [EGV18]).

The basic assumption in logical-based approaches is that preferences have structural properties that can be suitably described in a formalized language. This is the main goal of the so-called *preference logics*, see e.g. [HGY12]. The first logical systems to reason about preferences go back to S. Halldén [Hal57] and to von Wright [vW63], [vW72], [Liu10]. Others related works are [EP06], [vBvOR05]. More recently van Benthem et al. in [vBGR09] have presented a modal logic-based formalization of representing and reasoning with preferences. In that paper the authors first define a basic modal logic with two unary modal operators  $\diamond^{\leq}$  and  $\diamond^{<}$ , together with the universal and existential modalities,  $A$  and  $E$  respectively, and axiomatize them. Using these primitive modalities, they consider several (definable) binary modalities to capture different notions of preference relations on classical propositions, and show completeness with respect to the intended preference semantics. Finally they discuss their systems in relation to von Wright axioms for *ceteris paribus* preferences [vW63]. On the other hand, with the motivation of formalising a comparative notion of likelihood, Halpern studies in [Hal97] different ways to extend preorders on a set  $X$  to preorders on subsets of  $X$  and their associated strict orders. He studies their properties and relations among them, and he also provides an axiomatic system for a *logic of relative likelihood*, that is proved to be complete with respect to what he calls *preferential structures*, i.e. Kripke models with preorders as accessibility relations. All these works relate to the classical (modal) logic and crisp preference (accessibility) relations.

In the fuzzy setting, as far as the authors are aware, there are not many formal logic-based approaches to reasoning with fuzzy preference relations, see e.g. [BEFG01]. More recently, in the first part of [EGV18] we studied and characterized

Vidal is supported by the project no. CZ.02.2.69/0.0/0.0/17\_050/0008361, “Enhancing human resources for research in theoretical computer science”, funded by the Operational Programme Research, Development and Education of the Ministry of Education, Youth and Sports of the Czech Republic. Esteva and Godo acknowledge partial support by the FEDER/MINECO project TIN2015-71799-C2-1-P.



different forms to define fuzzy relations on the set  $\mathcal{P}(W)$  of subsets of  $W$ , from a fuzzy preorder on  $W$ , in a similar way to the one followed in [Hal97], [vBGR09] for classical preorders, while in the second part we have semantically defined and axiomatized several two-tiered graded modal logics to reason about different notions of preferences on crisp propositions, see also [EGV17]. On the other hand, in [VEG17a] we considered a modal framework over a many-valued logic with the aim of generalizing Van Benthem et al.'s modal approach to the case of both fuzzy preference accessibility relations and fuzzy propositions. To do that, we first extended the many-valued modal framework for only a necessity operator  $\Box$  of [BEGR11], by defining an axiomatic system with both necessity and possibility operators  $\Box$  and  $\Diamond$  over the same class of models. Unfortunately, in the last part of that paper, there is a mistake in the proof of Theorem 3 (particularly, equation (4)). This leaves open the question of properly axiomatizing the logic of graded preferences defined there.

In this paper we address this problem, and propose an alternative approach to provide a complete axiomatic system for a logic of fuzzy preferences. Namely, given a finite MTL-chain  $\mathbf{A}$  (i.e. a finite totally ordered residuated lattice) as set of truth values, and given an  $A$ -valued preference Kripke model  $(W, R, e)$ , with  $R$  a fuzzy preorder valued on  $A$ , we consider the  $a$ -cuts  $R_a$  of the relation  $R$  for every  $a \in A$ , and for each  $a$ -cut  $R_a$ , we consider the corresponding modal operators  $\Box_a, \Diamond_a$ . These operators are easier to be axiomatized, since the relations  $R_a$  are not fuzzy any longer, they are a nested set of classical (crisp) relations. The good news is that, in the our rich (multi-modal) logical framework, we can show that the original modal operators  $\Box$  and  $\Diamond$  are definable, and vice-versa if we expand the logic with Monteiro-Baaz's  $\Delta$  operator. So we obtain a different, but equivalent, system where the original operators can be properly axiomatized in an indirect way through the graded operators.

The paper is structured as follows. After this introduction, in Section II we present the multi-modal language and the intended semantics given by *graded preference Kripke models*, which allows the formalization of different notions dealing with preferences taking values in some arbitrary MTL-chain  $\mathbf{A}$ . In Section III, we discuss different possibilities to formalize notions of preferences on fuzzy propositions in preference Kripke models. In Section IV we will exhibit a complete axiomatization of an alternative preference logic that is not, however, equivalent to the one from [VEG17a], since the language is intrinsically different. Nevertheless, we will see in Section V how, by the addition to the logic of the so-called Monteiro-Baaz  $\Delta$  operation, we can also provide an axiomatization of the original logic of graded preference models pursued in [VEG17a]. We finish with some conclusions and open problems.

## II. A MULTI-MODAL PREFERENCE LOGIC: LANGUAGE AND SEMANTICS

Let us begin by defining the formal language of our underlying many-valued propositional setting. Let  $\mathbf{A} =$

$(A, \wedge, \vee, \odot, \rightarrow, 0, 1)$  be a *finite* and linearly ordered (bounded, integral, commutative) residuated lattice (equivalently, a finite MTL-chain) [GJKO07], and consider its canonical expansion  $\mathbf{A}^c$  by adding a new constant  $\bar{a}$  for every element  $a \in A$  (canonical in the sense that the interpretation of  $\bar{a}$  in  $\mathbf{A}^c$  is  $a$  itself). A negation operation  $\neg$  can always be defined as  $\neg x = x \rightarrow 0$ .

The logic associated with  $\mathbf{A}^c$  will be denoted by  $\Lambda(\mathbf{A}^c)$ , and its logical consequence relation  $\models_{\mathbf{A}^c}$  is defined as follows: for any set  $\Gamma \cup \{\varphi\} \subseteq \mathbf{Fm}$  of formulas built in the usual way from a set of propositional variables  $\mathcal{V}$  in the language of residuated lattices (we will use the same symbol to denote connectives and operations), including constants  $\{\bar{a} : a \in A\}$ ,

- $\Gamma \models_{\mathbf{A}^c} \phi$  if, and only if,  
 $\forall h \in \text{Hom}(\mathbf{Fm}, \mathbf{A}^c)$ , if  $h[\Gamma] \subseteq \{1\}$  then  $h(\phi) = 1$ ,

where  $\text{Hom}(\mathbf{Fm}, \mathbf{A}^c)$  denotes the set of evaluations of formulas on  $\mathbf{A}^c$ .

Lifting to the modal level, we extend the propositional language by graded modal operators  $\Box_a, \Diamond_a$ , one pair for each element  $a$  of the algebra  $\mathbf{A}$ . We let the set  $\mathbf{MFm}$  of *multi-modal formulas* defined as usual from a set  $\mathcal{V}$  of propositional variables, residuated lattice operations  $\{\wedge, \vee, \odot, \rightarrow\}$ , truth constants  $\{\bar{a} : a \in A\}$ , and modal operators  $\{\Box_a, \Diamond_a : a \in A\}$ .

We are now ready to introduce  $\mathbf{A}$ -valued preference Kripke models.

**Definition II.1.** An  $\mathbf{A}$ -preference model is a triple  $\mathfrak{M} = \langle W, R, e \rangle$  such that

- $W$  is a set of worlds,
- $R: W \times W \rightarrow A$  is an  $A$ -valued fuzzy pre-order, i.e. a reflexive and  $\odot$ -transitive  $A$ -valued binary relation between worlds, and
- $e: W \times \mathcal{V} \rightarrow A$  is a world-wise  $\mathbf{A}$ -evaluation of variables. This evaluation is uniquely extended to formulas of  $\mathbf{MFm}$  by using the operations in  $\mathbf{A}$  for what concerns propositional connectives, and letting for each  $a \in A$ ,

$$\begin{aligned} e(v, \Box_a \varphi) &= \bigwedge_{w: v \preceq_a w} \{e(w, \varphi)\} \\ e(v, \Diamond_a \varphi) &= \bigvee_{w: v \preceq_a w} \{e(w, \varphi)\} \end{aligned}$$

where  $v \preceq_a w$  stands for  $R(v, w) \geq a$ .

We will denote by  $\mathbb{P}_{\mathbf{A}}$  the class of  $\mathbf{A}$ -preference models. Given an  $\mathbf{A}$ -preference model  $\mathfrak{M} \in \mathbb{P}_{\mathbf{A}}$  and  $\Gamma \cup \{\varphi\} \subseteq \mathbf{MFm}$ , we write  $\Gamma \Vdash_{\mathfrak{M}} \varphi$  whenever for any  $v \in W$ , if  $e(v, \gamma) = 1$  for all  $\gamma \in \Gamma$ , then  $e(v, \varphi) = 1$  too. Analogously, we write  $\Gamma \Vdash_{\mathbb{P}_{\mathbf{A}}} \varphi$  whenever  $\Gamma \Vdash_{\mathfrak{M}} \varphi$  for any  $\mathfrak{M} \in \mathbb{P}_{\mathbf{A}}$ .

We will denote by differentiated names some particular definable modal operators that enjoy a special meaning in our models. Namely:

- $\Box \varphi := \bigwedge_{a \in A} \bar{a} \rightarrow \Box_a \varphi$  and  $\Diamond \varphi := \bigvee_{a \in A} \bar{a} \odot \Box_a \varphi$ .

It is easy to check that the evaluation of these operators in a preference model as defined here, coincides with the

usual one for fuzzy Kripke models, i.e.,

$$e(v, \Box\varphi) = \bigwedge_{w \in W} \{R(v, w) \rightarrow e(w, \varphi)\}$$

$$e(v, \Diamond\varphi) = \bigvee_{w \in W} \{R(v, w) \odot e(w, \varphi)\}$$

- $A\varphi := \Box_0\varphi$  and  $E\varphi := \Diamond_0\varphi$ .

Again, it is easy to see that these operators coincide with the global necessity and possibility modal operators respectively, i.e.,

$$e(v, A\varphi) = \bigwedge_{w \in W} \{e(w, \varphi)\}, \quad e(v, E\varphi) = \bigvee_{w \in W} \{e(w, \varphi)\}.$$

### III. MODELING FUZZY PREFERENCES ON PROPOSITIONS

The preference models introduced above are a very natural setting to formally address and reason over graded or fuzzy preferences over non-classical contexts. They are similar to the (classical) preference models studied by van Benthem et. al in [vBGR09], but offering a lattice of values (and so, a many-valued framework) where to evaluate both the truth degrees of formulas and the accessibility (preference) relation. The latter can be naturally interpreted as a graded preference relation between possible worlds or states (assignments of truth-values to variables). The question is then how to lift a (fuzzy) preference relation  $\leq$  on worlds to (fuzzy) preference relations among formulas.

In the classical case, for instance in [vBGR09], [EGV18] the following six extensions are considered, where  $[\varphi]$  and  $[\psi]$  denote the set of models of propositions  $\varphi$  and  $\psi$  respectively:

- $\varphi \leq_{\exists\exists} \psi$  iff  $\exists u \in [\varphi], v \in [\psi]$  such that  $u \leq v$
- $\varphi \leq_{\exists\forall} \psi$  iff  $\exists u \in [\varphi]$ , such that  $\forall v \in [\psi], u \leq v$
- $\varphi \leq_{\forall\exists} \psi$  iff  $\forall u \in [\varphi], \exists v \in [\psi]$  such that  $u \leq v$
- $\varphi \leq_{\forall\forall} \psi$  iff  $\forall u \in [\varphi]$  and  $v \in [\psi], u \leq v$
- $\varphi \leq_{\exists\forall 2} \psi$  iff  $\exists v \in [\psi]$ , such that  $\forall u \in [\varphi], u \leq v$
- $\varphi \leq_{\forall\exists 2} \psi$  iff  $\forall v \in [\psi], \exists u \in [\varphi]$  such that  $u \leq v$

However, not all these extensions can be expressed in our framework. For instance, we can express the orderings  $\leq_{\exists\exists}$  and  $\leq_{\forall\forall}$  as follows:

- $\varphi \leq_{\exists\exists} \psi := E(\varphi \wedge \Diamond\psi)$
- $\varphi \leq_{\forall\forall} \psi := A(\varphi \rightarrow \Diamond\psi)$

Some others would need to consider the inverse order  $\geq$  of  $\leq$  in the models or to assume the order  $\leq$  be total, and some other are not just expressible (see [vBGR09]). On the other hand, not all the extensions above are also equally reasonable, for instance some of them are not even preorders. This is not the case of  $\leq_{\forall\exists}$  and  $\leq_{\forall\exists 2}$ , that are indeed preorders.

In the fuzzy case, the formulas

$$E(\varphi \wedge \Diamond\psi), \\ A(\varphi \rightarrow \Diamond\psi)$$

make full sense as a fuzzy generalizations of the  $\leq_{\exists\exists}$  and  $\leq_{\forall\forall}$  preference orderings respectively, and moreover, as shown in

[VEG17a], the expression  $A(\varphi \rightarrow \Diamond\psi)$  models a fuzzy pre-order in formulas (i.e. it satisfies reflexivity and  $\odot$ -transitivity).

Using the graded modalities  $\Diamond_a$ , one could also consider other intermediate extensions like

$$E(\varphi \wedge \Diamond_a\psi), \\ A(\varphi \rightarrow \Diamond_a\psi)$$

which would correspond to the fuzzy extensions of the following preference orderings  $\leq_{\exists\exists}^a \leq_{\forall\forall}^a$  on crisp propositions defined from the  $a$ -cut of the fuzzy preorder  $R$ :

- $\varphi \leq_{\exists\exists}^a \psi$  iff  $\exists u \in [\varphi], \exists v \in [\psi]$  such that  $R(u, v) \geq a$ .
- $\varphi \leq_{\forall\forall}^a \psi$  iff  $\forall u \in [\varphi], \exists v \in [\psi]$  such that  $R(u, v) \geq a$ .

Indeed, given an  $\mathbf{A}$ -valued preference model  $\mathfrak{M} = \langle W, R, e \rangle$ , one can define the following fuzzy preference relations on formulas:

- $\varphi \preceq_{\exists\exists}^a \psi$  iff there are worlds  $v, w \in W$  such that  $R(v, w) \geq a$  and  $e(v, \varphi) \leq e(w, \psi)$
- $\varphi \preceq_{\forall\forall}^a \psi$  iff for each world  $v \in W$ , there is a world  $w \in W$  such that  $R(v, w) \geq a$  and  $e(v, \varphi) \leq e(w, \psi)$ .

Then, it is not difficult to check that

$$\Vdash_{\mathfrak{M}} E(\varphi \wedge \Diamond_a\psi) \text{ iff } \varphi \preceq_{\exists\exists}^a \psi \\ \Vdash_{\mathfrak{M}} A(\varphi \rightarrow \Diamond_a\psi) \text{ iff } \varphi \preceq_{\forall\forall}^a \psi.$$

So, we think our many-valued logical framework is expressive enough to capture many notions of (fuzzy) preferences among formulas. In the next section we provide an axiomatization for this fuzzy multi-modal preference logic.

### IV. AXIOMATIZING FUZZY PREFERENCE MODELS

In [VEG17a], we proposed the following axiomatic system  $\mathbb{P}_{\mathbf{A}}$ , in the language only with  $\Box$  and  $\Diamond$  modal operators (i.e. without the  $\Box_a$ 's and  $\Diamond_a$ 's):

- The axioms and rules of the minimal modal logic  $\mathbf{BM}_{\mathbf{A}}$  for the pairs  $(\Box, \Diamond)$  and  $(A, E)$  of modal operators (see [VEG17a, Def. 2])
- T:  $\Box\varphi \rightarrow \varphi, \varphi \rightarrow \Diamond\varphi, A\varphi \rightarrow \varphi, \varphi \rightarrow E\varphi$
- 4:  $\Box\varphi \rightarrow \Box\Box\varphi, \Diamond\Diamond\varphi \rightarrow \Diamond\varphi, A\varphi \rightarrow AA\varphi, EE\varphi \rightarrow E\varphi$
- B:  $\varphi \rightarrow AE\varphi$
- The *inclusion* axioms:  $A\varphi \rightarrow \Box\varphi, \Diamond\varphi \rightarrow E\varphi$

In [VEG17a, Th. 3], this system was claimed to be complete with respect to the class  $\mathbb{P}_{\mathbf{A}}$  of preference models. Unfortunately, we have discovered there is a flaw at the end of the proof, so the claim of the theorem remains unproved. In this section we remedy this problem by considering an alternative axiomatic system, based on the use of the graded modalities  $\Box_a$  and  $\Diamond_a$ , for  $a \in A$ , introduced in Section II.

To this end, we introduce next the axiomatic system  $\mathbf{mM}_{\mathbf{A}}$  defined by the following axioms and rules:

- 1) For each  $a \in A$ ,
  - Axioms of minimum modal logic  $\mathbf{BM}_{\mathbf{A}}$  for each pair of operators  $(\Box_a, \Diamond_a)$  (see [VEG17a, Def. 2])
- 2) For each  $a \in A$ , the axiom
  - $C_a: \Box_a(\bar{k} \vee \varphi) \rightarrow \bar{k} \vee \Box_a\varphi$
- 3) For each  $a, b \in A$ , axioms K, T and 4:



- $K_a: \Box_a(\varphi \rightarrow \psi) \rightarrow (\Box_a\varphi \rightarrow \Box_a\psi)$
  - $T_a: \Box_a\varphi \rightarrow \varphi, \quad \varphi \rightarrow \Diamond_a\varphi$
  - $4_{a,b}: \Box_a\Box_b\varphi \rightarrow \Box_a\Box_b\varphi, \quad \Diamond_a\Diamond_b\varphi \rightarrow \Diamond_a\Diamond_b\varphi$
- 4) For each  $a \leq b$ , nestedness axioms:
- $\Box_a\varphi \rightarrow \Box_b\varphi, \quad \Diamond_b\varphi \rightarrow \Diamond_a\varphi$
- 5) For  $a = 0$ , axiom
- $B_0: \varphi \rightarrow \Box_0\Diamond_0A$
- 6) Rules: Modus Ponens and the necessitation for  $\Box_0$ :<sup>1</sup>
- from  $\varphi$  derive  $\Box_0\varphi$

Letting  $\vdash_{\text{mM}_A}$  be the consequence relation of the previous axiomatic system defined as usual, we can show that it is indeed complete with respect to our intended semantics given by the class of preference structures  $\Vdash_{\mathbb{P}_A}$ . Formally,

**Theorem IV.1.** For any  $\Gamma, \varphi \subseteq \mathbf{MFm}$ ,

$$\Gamma \vdash_{\text{mM}_A} \varphi \text{ if and only if } \Gamma \Vdash_{\mathbb{P}_A} \varphi.$$

*Proof.* Soundness (left to right direction) is easy to check. For what concerns completeness (right to left direction), we can define a canonical model

$$\mathfrak{M}^c = (W^c, \{R_a^c\}_{a \in A}, e^c)$$

with a set of crisp accessibility relations as follows, where  $Th(\text{mM}_A) = \{\varphi : \vdash_{\text{mM}_A} \varphi\}$  denotes the set of theorems of  $\text{mM}_A$ :

- $W^c = \{v \in Hom(\mathbf{MFm}, \mathbf{A}) : v(Th(\text{mM}_A)) = \{1\}\}$ ,
- $R_a^c(v, w)$  if and only if  $v(\Box_a\varphi) = 1 \Rightarrow w(\varphi) = 1$  for all  $\varphi \in \mathbf{MFm}$ ,
- $e^c(v, p) = v(p)$ , for any propositional variable  $p$ .

It is clear (since the only modal inference rules affects only theorems of the logic) that if  $\Gamma \Vdash_{\text{mM}_A} \varphi$ , then there is  $v \in W^c$  such that  $v(\Gamma) \subset \{1\}$  and  $v(\varphi) < 1$ . It is then only necessary to prove that the evaluation in the model can be defined in that way, namely, to prove the corresponding Truth Lemma, which follows from [BEGR11] and [VEG17a], i.e., for each formula  $\varphi \in \mathbf{MFm}$  and each  $v \in W^c$ , it holds that

$$e^c(v, \Box_a\varphi) = \bigwedge_{R_a^c(v, w)} w(\varphi) \text{ and } e^c(v, \Diamond_a\varphi) = \bigvee_{R_a^c(v, w)} w(\varphi).$$

The nestedness axioms allow us to easily prove that for any  $a \leq b \in A$ , it holds that  $R_b^c \subseteq R_a^c$ . Consider then the fuzzy relation  $R^c$  defined by

$$R^c(v, w) = \max\{a \in A : R_a^c(v, w)\}.$$

It is clear that  $R^c(w, v) \geq a$  if and only if  $R_a^c(v, w)$ . Then, the truth lemma for the original model directly implies both

$$e^c(v, \Box_a\varphi) = \bigwedge_{w \in W^c, R^c(v, w) \geq a} w(\varphi),$$

$$e^c(v, \Diamond_a\varphi) = \bigvee_{w \in W^c, R^c(v, w) \geq a} w(\varphi).$$

<sup>1</sup>Observe that, together with the nestedness axioms, this rule implies the necessitation rule for each  $\Box_a$ .

It follows from axioms  $T_a$  that each  $R_a^c$  is reflexive, and so,  $R^c$  is a reflexive relation as well. Moreover, from axioms  $4_{a,b}$ , we get that  $R^c$  is  $\odot$ -transitive. The only remaining step is to prove is that we can obtain an equivalent model (in the sense of preserving the truth-values of formulas) in which  $R_0^c$  is the total relation (in order to really get that  $\Box_0$  and  $\Diamond_0$  are global modalities). Observe that in the model defined above, thanks to axioms  $T_0, 4_{0,0}$  and  $B_0$ ,  $R_0^c$  can be proven to be an equivalence relation, even though it is not necessarily the case that  $R_0^c = W^c \times W^c$ . Nevertheless, since  $R_b^c \subseteq R_0^c$  for all  $b \in A$ , for any arbitrary  $v \in W^c$ , we can define the model  $\mathfrak{M}_v^c$  from  $\mathfrak{M}^c$  by restricting the universe to  $W_v^c = \{u \in W^c : R_0^c(v, u)\}$  and get that, for any  $u \in W_v^c$  and any formula  $\varphi \in \mathbf{MFm}$ ,

$$e^c(u, \varphi) = e_v^c(u, \varphi).$$

All the previous considerations allow us to prove that if  $\Gamma \Vdash_{\text{mM}_A} \varphi$  there is  $v \in W_v^c$  such that  $e_v^c(v, \Gamma) \subseteq 1$  and  $e_v^c(v, \varphi) < 1$ . Given that the model  $\mathfrak{M}_v^c$  defined above is indeed an  $\mathbf{A}$ -preference model, this concludes the completeness proof.  $\square$

## V. CLOSING THE LOOP: FROM GRADED TO FUZZY MODALITIES

In the previous section, we have seen that we have been able to provide a complete axiomatic system  $\text{mM}_A$  for the graded preference modalities  $\Box_a$ 's and  $\Diamond_a$ 's, and in Section II we have seen that the original fuzzy modalities  $\Box$  and  $\Diamond$  can be expressed from them. Thus, the system  $\text{mM}_A$  can be considered in fact as a sort of indirect axiomatization of the modalities  $\Box$  and  $\Diamond$  as well. In this section, generalising an approach introduced in [BEGR09], we will see that, by enriching our language with the well-known Monteiro-Baaz  $\Delta$  connective (see e.g. [Háj98]), the graded modalities  $\Box_a, \Diamond_a$  can also be expressed in terms of the original modal operators  $\Box$  and  $\Diamond$ . Surprisingly enough we can do it using only the  $\Diamond$  operator, while it is not clear using only  $\Box$  would suffice.

Recall that the Monteiro-Baaz  $\Delta$  operation over a linearly ordered MTL-chain  $\mathbf{A}$  is the operation defined as

$$\Delta(a) = \begin{cases} 1 & \text{if } a = 1 \\ 0 & \text{otherwise} \end{cases}$$

for all  $a \in A$ .

In the following, we will write  $\varphi \equiv \psi$  to denote that  $\varphi$  and  $\psi$  are logically equivalent in the class of preference models  $\mathbb{P}_A$ . We will also denote by  $\varphi \approx \bar{b}$  the formula  $\Delta(\varphi \leftrightarrow \bar{b})$ .

**Lemma V.1.**

$$\Box_a\varphi \equiv \bigwedge_{b \in A} (\Delta(\bar{a} \rightarrow \Diamond(\varphi \approx \bar{b})) \rightarrow \bar{b})$$

$$\Diamond_a\varphi \equiv \bigvee_{b \in A} (\Delta(\bar{a} \rightarrow \Diamond(\varphi \approx \bar{b})) \& \bar{b})$$

*Proof.* As in [BEGR09] we can check that

$$e(v, \Diamond(\varphi \approx \bar{b})) = \bigvee_{e(w, \varphi) = \bar{b}} R(v, w).$$

Then  $e(v, \Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b}))) = \Delta(a \rightarrow \bigvee_{e(w, \varphi) \approx b} R(v, w))$ ,  
and thus

$$e(v, \Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b}))) = \begin{cases} 1, & \text{if } a \leq \bigvee_{e(w, \varphi) \approx b} R(v, w) \\ 0, & \text{otherwise} \end{cases}.$$

Letting  $S = \{b \in A : a \leq \bigvee_{e(w, \varphi) \approx b} R(v, w)\}$ , the previous trivially implies both that

$$e(v, \Delta(\bar{a} \rightarrow \diamond(\varphi = \bar{b})) \rightarrow \bar{b}) = \begin{cases} b, & \text{if } b \in S \\ 1, & \text{otherwise} \end{cases}$$

$$e(v, \Delta(\bar{a} \rightarrow \diamond(\varphi = \bar{b})) \& \bar{b}) = \begin{cases} b, & \text{if } b \in S \\ 0, & \text{otherwise} \end{cases}.$$

Moreover, it is easy to see that

$$\{b \in A : a \leq \bigvee_{e(w, \varphi) \approx b} R(v, w)\} = \{e(w, \varphi) : a \leq Rvw\}.$$

Then, we have

$$\begin{aligned} e(v, \bigwedge_{b \in A} (\Delta(\bar{a} \rightarrow \diamond(\varphi = \bar{b})) \rightarrow \bar{b})) &= \bigwedge S = \\ &= \bigwedge_{a \leq R(v, w)} e(w, \varphi) = e(v, \Box_a \varphi) \\ \text{and } e(v, \bigvee_{b \in A} (\Delta(\bar{a} \rightarrow \diamond(\varphi = \bar{b})) \& \bar{b})) &= \bigvee S = \\ &= \bigvee_{a \leq R(v, w)} e(w, \varphi) = e(v, \diamond_a \varphi), \text{ concluding the proof. } \quad \square \end{aligned}$$

It is then the case that it is possible to provide an axiomatization for the fragment with only  $\Box, \diamond, A$  and  $E$  of the logic  $\Vdash_{\mathbb{P}_A}$  plus  $\Delta$ . First, it is easy to provide an axiomatic system for the whole logic  $\Vdash_{\mathbb{P}_A}$  plus  $\Delta$  by adding to  $mM_A$  an axiomatization for  $\Delta$  (see eg. [Háj98], [VEG17b]) and the interaction axioms

$$\Delta \Box_a \varphi \rightarrow \Box_a \Delta \varphi.$$

From here, it is clear that we can use the interdefinability of  $\Box_a, \diamond_a$  from  $\diamond$  proven above, and obtain in that way an axiomatic system complete with respect to the intended semantics.

This system is, however, quite more involved than the one presented in [VEG17a] (that did not achieve completeness with respect to its intended semantics). An open problem for future works is to study possible simplifications of this axiomatization, since the  $(\Box, \diamond, A, E)$ -fragment is possibly the best suited to formalise graded preference relations while maintaining a lower level of elements in the language (and so, probably a lower complexity level).

As a side result, the previous characterization allows us to get a definition of the  $\Box$  operation in terms of the  $\diamond$  very different from the usual one arising in classical modal logic. In particular, we get the following result.

**Lemma V.2.**

$$\Box \varphi \equiv \bigwedge_{a \in A} \bigwedge_{b < a \in A} \Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b})) \rightarrow \overline{(a \rightarrow b)}$$

*Proof.* We know by definition that

$$\Box \varphi \equiv \bigwedge_{a \in A} \bar{a} \rightarrow \Box_a \varphi.$$

Then, using the previously proven equivalences, we prove the lemma by the following chain of equalities

$$\begin{aligned} \Box \varphi &\equiv \bigwedge_{a \in A} (\bar{a} \rightarrow \bigwedge_{b \in A} (\Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b})) \rightarrow \bar{b})) \\ &\equiv \bigwedge_{a \in A} \bigwedge_{b \in A} \bar{a} \rightarrow (\Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b})) \rightarrow \bar{b}) \\ &\equiv \bigwedge_{a \in A} \bigwedge_{b \in A} \Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b})) \rightarrow (\bar{a} \rightarrow \bar{b}) \\ &\equiv \bigwedge_{a \in A} \bigwedge_{b < a \in A} \Delta(\bar{a} \rightarrow \diamond(\varphi \approx \bar{b})) \rightarrow \overline{(a \rightarrow b)} \end{aligned}$$

□

## VI. CONCLUSIONS AND ONGOING WORK

The aim of this work is to provide a formal framework generalising the treatment of preferences in the style of eg. [vBGR09] to a fuzzy context. We have presented an axiomatic system encompassing reflexive and transitive modalities plus global operators, that is shown to be the syntactical counterpart of many-valued Kripke models with (reflexive and transitive) graded (weak) preference relations between possible worlds or states. It is based on considering the cuts of the relations over the elements of the algebra of evaluation, solving in this way some problems arising from [VEG17a], for what concerns systems extended with the projection connective  $\Delta$ . This logical framework stands towards the use of modal many-valued logics in the representation and management of graded preferences, in the same fashion that (classical) modal logic has served in the analogous Boolean preference setting.

The generalization of the previous logical system to cases when strict preferences are taken into account is part of ongoing work. The addition of those operators would allow a richer axiomatic definition of preference relations between formulas, in the sense of Section III. Moreover, further study of the introduced preference models should be pursued towards the formalisation of particular notions like indifference or incomparability, and aiming towards the incorporation of these systems in graded reasoners or recommender systems.

On the other hand, the study of the previous systems over other classes of algebras of truth-values (e.g. including infinite algebras like those defined on the real unit interval  $[0, 1]$  underlying Łukasiewicz, Product or Gödel fuzzy logics) is also of great interest, both from a theoretical point of view and towards the modelization of situations needing of continuous sets of values.

## REFERENCES

- [BD08] U. Bodenhofer and M. Demirci. Strict fuzzy orderings with a given context of similarity. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 16(2):147–178, 2008.
- [BEFG01] B. De Baets, F. Esteva, J. Fodor, and L. Godo. Systems of ordinal fuzzy logic with application to preference modelling. *Fuzzy Sets and Systems*, 124(3):353–359, 2001. Fuzzy logic (Palma, 1999/Liptovský Ján, 2000).



- [BEGR09] F. Bou, F. Esteva, L. Godo, and R. Rodríguez. Characterizing fuzzy modal semantics by fuzzy multimodal systems with crisp accessibility relations. In *Proc. of the Joint 2009 IFSA World Congress and 2009 EUSFLAT Conference, Lisbon, Portugal, 20-24 July 2009*, pages 1541–1546, 2009.
- [BEGR11] F. Bou, F. Esteva, L. Godo, and R. Rodríguez. On the minimum many-valued modal logic over a finite residuated lattice. *Journal of Logic and Computation*, 21(5):739–790, 2011.
- [Bod08a] U. Bodenhofer. Orderings of fuzzy sets based on fuzzy orderings part i: The basic approach. *Mathware and Soft Computing*, 15(2):201–218, 2008.
- [Bod08b] U. Bodenhofer. Orderings of fuzzy sets based on fuzzy orderings part ii: Generalizations. *Mathware and Soft Computing*, 15(3):219–249, 2008.
- [DBM07] S. Díaz, B. De Baets, and S. Montes. Additive decomposition of fuzzy pre-orders. *Fuzzy Sets and Systems*, 8:830–842, 2007.
- [DBM08] S. Díaz, B. De Baets, and S. Montes. On the compositional characterization of complete fuzzy pre-orders. *Fuzzy Sets and Systems*, 159(17):2221–2239, 2008.
- [DBM10] S. Díaz, B. De Baets, and S. Montes. General results on the decomposition of transitive fuzzy relations. *Fuzzy optimization and Decision Making*, 9(1):1–29, 2010.
- [DGLM08] S. Díaz, J.L. García-Lapresta, and S. Montes. Consistent models of transitivity for reciprocal preferences on a finite ordinal scale. *Information Sciences*, 178(13):2832–2848, 2008.
- [DHKP11] C. Domshlak, E. Hüllermeier, S. Kaci, and H. Prade. Preferences in AI: An overview. *Artificial Intelligence*, 175(7-8):1037–1052, 2011.
- [DMB04] S. Díaz, S. Montes, and B. De Baets. Transitive decomposition of fuzzy preference relations: the case of nilpotent minimum. *Kybernetika*, 40(1):71–88, 2004.
- [EGV17] F. Esteva, L. Godo, and A. Vidal. On a graded modal logic approach to reason with fuzzy preferences. In I. Aguiló et al., editor, *Recent Advances in Artificial Intelligence Research and Development - Proc. of CCA'17*, volume 300 of *Frontiers in Artificial Intelligence and Applications*, pages 86–95. IOS Press, 2017.
- [EGV18] F. Esteva, L. Godo, and A. Vidal. A modal account of preference in a fuzzy setting. In D. Pelta and C. Cruz Corona, editors, *Soft Computing Based Optimization and Decision Models*, volume 360 of *Studies in Fuzziness and Soft Computing*, pages 241–260. Springer, Cham, 2018.
- [EP06] U. Endriss and E. Pacuit. Modal logics of negotiation and preference. In M. Fisher, W. van der Hoek, B. Konev, and A. Lisitsa, editors, *Proceedings of the 10th European Conference on Logics in Artificial Intelligence (JELIA-2006)*, volume 4160 of *LNAI*, pages 138–150. Springer-Verlag, September 2006.
- [FR94] J. Fodor and M. Roubens. *Fuzzy Preference Modeling and Multicriteria Decision Support*. Kluwer Academic Publishers, 1994.
- [GJKO07] N. Galatos, P. Jipsen, T. Kowalski, and H. Ono. *Residuated Lattices: an algebraic glimpse at substructural logics*, volume 151 of *Studies in Logic and the Foundations of Mathematics*. Elsevier, Amsterdam, 2007.
- [Háj98] P. Hájek. *Metamathematics of fuzzy logic*, volume 4 of *Trends in Logic—Studia Logica Library*. Kluwer Academic Publishers, Dordrecht, 1998.
- [Hal57] S. Halldén. On the logic of better. *Library of Theoria*, 2, 1957.
- [Hal97] J.Y. Halpern. Defining relative likelihood in partially-ordered preference structures. *Journal of Artificial Intelligence Research*, 7:1–24, 1997.
- [HGY12] S.O. Hansson and Till Grüne-Yanoff. *Preferences. The Stanford Encyclopedia of Philosophy*. 2012.
- [Kac11] S. Kaci. *Working with Preferences: Less Is More*. Cognitive Technologies. Springer, 2011.
- [Liu10] F. Liu. Von wright’s “the logic of preference” revisited. *Synthese*, 175(1):69–88, 2010.
- [vBGR09] J. van Benthem, P. Girard, and O. Roy. Everything else being equal: A modal logic for ceteris paribus preferences. *Journal of Philosophical Logic*, 38:83–125, 2009.
- [vBvOR05] J. van Benthem, S. van Otterloo, and O. Roy. Preference logic, conditionals and solution concepts in games. Research Report PP-2005-28, Institute for Logic, Language and Computation, University of Amsterdam, Amsterdam, 2005.
- [VEG17a] A. Vidal, F. Esteva, and L. Godo. On finite-valued bimodal logics with an application to reasoning about preferences. In *Proceedings of EUSFLAT 2017, Advances in Fuzzy Logic and Technology 2017*, pages 505–517, 2017.
- [VEG17b] A. Vidal, F. Esteva, and L. Godo. On modal extensions of product fuzzy logic. *Journal of Logic and Computation*, 27(1):299–336, 2017.
- [vW63] G.H. von Wright. *The Logic of Preference*. Edinburg University Press, 1963.
- [vW72] G.H. von Wright. The logic of preference reconsidered. *Theory and Decision*, 3(2):140–169, 1972.

# Stable models in multi-adjoint normal logic programs

M. Eugenia Cornejo, David Lobo and Jesús Medina

Department of Mathematics, University of Cádiz

Email: {mariaeugenia.cornejo,david.lobo,jesus.medina}@uca.es

**Abstract**—Multi-adjoint normal logic programming arises as an extension of multi-adjoint logic programming considering a negation operator in the underlying lattice. In the literature, we can find different semantics for logic programs with negation [3]–[5]. We are interested in considering the stable model semantics in our logic programming framework. This paper summarizes a broad study on the syntax and semantics of multi-adjoint normal logic programming framework which has been recently published in [1]. Specifically, we will analyze the existence and the unicity of stable models for multi-adjoint normal logic programs.

**Index Terms**—multi-adjoint logic programs, negation operator, stable models

## I. INTRODUCTION

Multi-adjoint logic programming was introduced in [9] as a general logic programming framework in which several implications appear in the rules of a same logic program and any order-preserving operator is allowed in the body of its rules. An interesting consequence of considering order-preserving operators in the body of the rules is associated with the existence of a least model. This fact makes possible to check whether a statement is a consequence of the logic program by simply computing the truth value of the statement under the least model. Therefore, the semantics of a multi-adjoint logic program is based on the least model of the program.

A well known fact in the logic programming literature is that the use of a negation operator increases the flexibility of a logic programming language. We are interested in enriching the multi-adjoint logic programming environment with the inclusion of a negation operator, which will give rise to a new kind of logic programs called multi-adjoint normal logic programs. It is important to emphasize that the existence of minimal models in an arbitrary multi-adjoint normal logic program cannot be ensured, in general. Furthermore, minimal models are not enough in order to prove that a statement is a consequence of a multi-adjoint normal logic program. As a result, the semantics of multi-adjoint normal logic programs will not be based on the notion of minimal model, but on the notion of stable model.

Different semantics such as the well-founded semantics [3], the stable models semantics [4] and the answer sets semantics [5] have been developed for logic programs with negation.

Partially supported by the State Research Agency (AEI) and the European Regional Development Fund (ERDF) project TIN2016-76653-P, and by the research and transfer program of the University of Cádiz.

In this paper, we will focus on the study of the existence and the unicity of stable models for multi-adjoint normal logic programs. According to the literature, sufficient conditions to ensure the existence of stable models have already been stated in other logical approaches [2], [6], [7], [10]–[13].

This paper will present a brief summary on the syntax and semantics defined for multi-adjoint normal logic programs in [1], including the most important results related to the existence and the unicity of stable models. In particular, we will show sufficient conditions which ensure the existence of stable models for multi-adjoint normal logic programs defined on any convex compact set of an euclidean space. Besides, in what regards the uniqueness of stable models, sufficient conditions for multi-adjoint normal logic programs defined on the set of subintervals  $[0, 1] \times [0, 1]$  will be provided.

## II. MULTI-ADJOINT NORMAL LOGIC PROGRAMS

The syntax of multi-adjoint normal logic programs is based on an algebraic structure composed by a complete bounded lattice together with various adjoint pairs and a negation operator. This algebraic structure is usually known as multi-adjoint normal lattice and it is formally defined as follows.

**Definition 1.** *The tuple  $(L, \preceq, \leftarrow_1, \&_1, \dots, \leftarrow_n, \&_n, \neg)$  is a multi-adjoint normal lattice if the following properties are verified:*

- 1)  $(L, \preceq)$  is a bounded lattice, i.e. it has a bottom ( $\perp$ ) and a top ( $\top$ ) element;
- 2)  $(\&_i, \leftarrow_i)$  is an adjoint pair in  $(L, \preceq)$ , for  $i \in \{1, \dots, n\}$ ;
- 3)  $\top \&_i \vartheta = \vartheta \&_i \top = \vartheta$ , for all  $\vartheta \in L$  and  $i \in \{1, \dots, n\}$ .
- 4)  $\neg$  is a negation operator, that is, a decreasing mapping  $\neg: L \rightarrow L$  satisfying the equalities  $\neg(\perp) = \top$  and  $\neg(\top) = \perp$ .

A multi-adjoint normal logic program is defined from a multi-adjoint normal lattice as a set of weighted rules.

**Definition 2.** *Let  $(L, \preceq, \leftarrow_1, \&_1, \dots, \leftarrow_n, \&_n, \neg)$  be a multi-adjoint normal lattice. A multi-adjoint normal logic program (MANLP)  $\mathbb{P}$  is a finite set of weighted rules of the form:*

$$\langle p \leftarrow_i @ [p_1, \dots, p_m, \neg p_{m+1}, \dots, \neg p_n]; \vartheta \rangle$$

where  $i \in \{1, \dots, n\}$ ,  $@$  is an aggregator operator,  $\vartheta$  is an element of  $L$  and  $p, p_1, \dots, p_n$  are propositional symbols such that  $p_j \neq p_k$ , for all  $j, k \in \{1, \dots, n\}$ , with  $j \neq k$ .



Let  $\mathbb{P}$  be a MANLP and  $\Pi_{\mathbb{P}}$  the set of propositional symbols in  $\mathbb{P}$ . Then, an interpretation is any mapping  $I: \Pi_{\mathbb{P}} \rightarrow L$ . We will say that an interpretation  $I$  satisfies a rule in  $\mathbb{P}$  of the form  $\langle p \leftarrow_i @ [p_1, \dots, p_m, \neg p_{m+1}, \dots, \neg p_n]; \vartheta \rangle$  if and only if its evaluation under  $I$  is greater or equal than the confidence factor associated with the rule, that is:

$$\vartheta \preceq \hat{I}(p \leftarrow_i @ [p_1, \dots, p_m, \neg p_{m+1}, \dots, \neg p_n])$$

A model is an interpretation that satisfies all rules in  $\mathbb{P}$ . As it was stated previously, the semantics of MANLPs is based on stable models. The notion of stable model is closely related to the notion of reduct given by Gelfond and Lifchitz [4]. Now, we will define the notion of reduct for MANLPs.

Given a MANLP  $\mathbb{P}$  and an interpretation  $I$ , we build the reduct of  $\mathbb{P}$  with respect to  $I$ , denoted by  $\mathbb{P}_I$ , by substituting each rule in  $\mathbb{P}$  of the form

$$\langle p \leftarrow_i @ [p_1, \dots, p_m, \neg p_{m+1}, \dots, \neg p_n]; \vartheta \rangle$$

by the rule

$$\langle p \leftarrow_i @_I [p_1, \dots, p_m]; \vartheta \rangle$$

where the operator  $@_I: L^m \rightarrow L$  is defined as

$$\dot{@}_I[\vartheta_1, \dots, \vartheta_m] = \dot{@}[\vartheta_1, \dots, \vartheta_m, \dot{\neg} I(p_{m+1}), \dots, \dot{\neg} I(p_n)]$$

for all  $\vartheta_1, \dots, \vartheta_m \in L$ .

**Definition 3.** Given a MANLP  $\mathbb{P}$  and an  $L$ -interpretation  $I$ , we say that  $I$  is a stable model of  $\mathbb{P}$  if and only if  $I$  is a minimal model of  $\mathbb{P}_I$ .

### III. ON THE EXISTENCE AND UNICITY OF STABLE MODELS

After introducing the main notions associated with the syntax and semantics of multi-adjoint normal logic programs, sufficient conditions which ensure the existence and the uniqueness of stable models will be provided.

First of all, we will show that any MANLP defined on a non-empty convex compact set in an euclidean space has at least a stable model, whenever the operators appearing in the MANLP are continuous operators. Formally:

**Theorem 4.** Let  $(K, \preceq, \leftarrow_1, \&_1, \dots, \leftarrow_n, \&_n, \neg)$  be a multi-adjoint normal lattice where  $K$  is a non-empty convex compact set in an euclidean space and  $\mathbb{P}$  be a finite MANLP defined on this lattice. If  $\&_1, \dots, \&_n, \neg$  and the aggregator operators in the body of the rules of  $\mathbb{P}$  are continuous operators, then  $\mathbb{P}$  has at least a stable model.

As far as the uniqueness of stable models is concerned, a special algebraic structure is considered and sufficient conditions from which we can ensure the unicity of stable models for multi-adjoint normal logic programs defined on the set of subintervals of  $[0, 1] \times [0, 1]$ , denoted by  $\mathcal{C}([0, 1])$ , are given. The considered algebraic structure is mainly composed by conjunctions defined as

$$\&_{\beta\delta}^{\alpha\gamma}([a, b], [c, d]) = [a^\alpha * c^\gamma, b^\beta * d^\delta]$$

with  $a, b, c, d \in \mathbb{R}$ , together with their residuated implications [8].

**Theorem 5.** Let  $\mathbb{P}$  be a finite MANLP defined on  $(\mathcal{C}([0, 1]), \preceq, \leftarrow_{\beta_1\delta_1}^{\alpha_1\gamma_1}, \&_{\beta_1\delta_1}^{\alpha_1\gamma_1}, \dots, \leftarrow_{\beta_m\delta_m}^{\alpha_m\gamma_m}, \&_{\beta_m\delta_m}^{\alpha_m\gamma_m}, \neg)$  such that the only possible operators in the body of the rules are  $\&_{\beta\delta}^{\alpha\gamma}$ , with  $\alpha = \beta = \gamma = \delta = 1$ , and  $[\vartheta_1^1, \vartheta_1^2] = \max\{[\vartheta^1, \vartheta^2] \mid \langle p \leftarrow_{\beta_w\delta_w}^{\alpha_w\gamma_w} \mathcal{B}; [\vartheta^1, \vartheta^2] \rangle \in \mathbb{P}\}$ . If the inequality

$$\sum_{j=1}^h (\vartheta^2)^{\beta_w} \cdot \delta_w \cdot (\vartheta_{q_j}^2)^{\delta_w-1} \cdot \left( \vartheta_{q_1}^2 \dots \vartheta_{q_{j-1}}^2 \cdot \vartheta_{q_{j+1}}^2 \dots \vartheta_{q_h}^2 \right)^{\delta_w} + (\vartheta^2)^{\beta_w} \cdot \delta_w \cdot (k-h) (\vartheta_{q_1}^2 \dots \vartheta_{q_h}^2)^{\delta_w} < 1$$

holds for every rule  $\langle p \leftarrow_{\beta_w\delta_w}^{\alpha_w\gamma_w} q_1 * \dots * q_h * \neg q_{h+1} * \dots * \neg q_k; [\vartheta^1, \vartheta^2] \rangle \in \mathbb{P}$ , with  $w \in \{1, \dots, m\}$ , then there exists a unique stable model of  $\mathbb{P}$ .

### IV. CONCLUSIONS AND FUTURE WORK

The philosophy of the multi-adjoint paradigm has been considered in order to define the syntax and semantics of a novel and flexible logic programming framework with negation. Moreover, we have shown under what conditions the existence and the unicity of stable models in multi-adjoint normal logic programs are guaranteed.

As a future work, we are interested in applying the obtained results to other logics with negation operators.

### REFERENCES

- [1] M. E. Cornejo, D. Lobo, and J. Medina. Syntax and semantics of multi-adjoint normal logic programming. *Fuzzy Sets and Systems*, 345:41–62, 2018.
- [2] M. Fitting. The family of stable models. *The Journal of Logic Programming*, 17(2-4):197–225, 1993.
- [3] A. V. Gelder, K. A. Ross, and J. S. Schlipf. The well-founded semantics for general logic programs. *Journal of the ACM*, 38(3):619–649, jul 1991.
- [4] M. Gelfond and V. Lifschitz. The stable model semantics for logic programming. In *Logic Programming, Proceedings of the Fifth International Conference and Symposium, Seattle, Washington, August 15-19, 1988 (2 Volumes)*, pages 1070–1080. MIT Press, 1988.
- [5] M. Gelfond and V. Lifschitz. Classical negation in logic programs and disjunctive databases. *New Generation Computing*, 9(3-4):365–385, aug 1991.
- [6] Y. Loyer and U. Straccia. Epistemic foundation of stable model semantics. *Journal of Theory and Practice of Logic Programming*, pages 355–393, 2006.
- [7] N. Madrid and M. Ojeda-Aciego. On the existence and unicity of stable models in normal residuated logic programs. *International Journal of Computer Mathematics*, 89(3):310–324, feb 2012.
- [8] J. Medina. Adjoint pairs on interval-valued fuzzy sets. In E. Hüllermeier, R. Kruse, and F. Hoffmann, editors, *Information Processing and Management of Uncertainty in Knowledge-Based Systems*, volume 81 of *Communications in Computer and Information Science*, pages 430–439. Springer, 2010.
- [9] J. Medina, M. Ojeda-Aciego, and P. Vojtáš. Multi-adjoint logic programming with continuous semantics. In *Logic Programming and Non-Monotonic Reasoning, LPNMR'01*, pages 351–364. Lecture Notes in Artificial Intelligence 2173, 2001.
- [10] T. Przymusiński. Well-founded semantics coincides with three-valued stable semantics. *Fundamenta Informaticae* 13, pages 445–463, 1990.
- [11] U. Straccia. Query answering in normal logic programs under uncertainty. *Lect. Notes in Computer Science*, 3571:687–700, 2005.
- [12] U. Straccia. Query answering under the any-world assumption for normal logic programs. *Lect. Notes in Computer Science*, 3571:687–700, 2006.
- [13] U. Straccia. A top-down query answering procedure for normal logic programs under the any-world assumption. *Proc. of the 10th Intl Conf on Principles of Knowledge Representation*, pages 329–339, 2006.

# Galois connections between a fuzzy preordered structure and a general fuzzy structure

I.P. Cabrera, P. Cordero, F. García-Pardo, M. Ojeda-Aciego

Depto. de Matemática Aplicada  
Universidad de Málaga, Spain  
Email: aciego@uma.es

B. De Baets

Dept of Mathematical Modelling,  
Statistics and Bioinformatics  
Ghent University, Belgium

**Abstract**—Key work presentation based on the paper of the same title published in *IEEE Transactions on Fuzzy Systems*, 26(3):1274-1287, 2018.

## EXTENDED ABSTRACT

Galois connections (both in isotone and in antitone forms) can be found in different areas, and it is common to find papers dealing with them either from a practical or a theoretical point of view. In the literature, one can find numerous papers on theoretical developments on (fuzzy) Galois connections [1], [19], [21] and also on applications thereof [13], [14], [22], [25], [28], [30], [33]. One important specific field of application is that of (Fuzzy) Mathematical Morphology, in which the (fuzzy) erosion and dilation operations are known to form a Galois connection, consider [6], [11], [20], [31], [32]; another important source of applications of Galois connections is within the field of (Fuzzy) Formal Concept Analysis, in which the concept-forming operators form either an antitone or isotone Galois connection (depending on the specific definition); in this research direction, one still can find recent papers on the theoretical background of the discipline [2]–[4], [8], [24], [29] and a number of applications [10], [26], [27].

Concerning the generalization of Galois connections to the fuzzy case, to the best of our knowledge, after the initial approach by Bělohávek [1], a number of authors have introduced different approaches to so-called fuzzy (isotone or antitone) Galois connections; see [5], [14], [15], [19], [21], [23], [34]. It is remarkable that the mappings forming the Galois connection in all the above-mentioned approaches are crisp rather than fuzzy. In our opinion the term ‘fuzzy Galois connection’ should be reserved for the case in which the involved mappings are actually fuzzy mappings, and that is why we prefer to stick to the term ‘Galois connection’ rather than ‘fuzzy Galois connection’, notwithstanding the fact that we are working in the context of fuzzy structures.

In previous works, some of the authors have studied the problem of constructing a right adjoint (or residual mapping) associated to a given mapping  $f: \mathbb{A} \rightarrow B$  where  $\mathbb{A}$  is endowed with some order-like structure and  $B$  is unstructured: in [18], we consider  $\mathbb{A}$  to be a crisp partially (pre)ordered set  $\langle A, \leq_A \rangle$ ; later, in [7], we considered  $\mathbb{A}$  to be a fuzzy preposet  $\langle A, \rho_A \rangle$ .

In this paper, we consider the case in which there are two underlying fuzzy equivalence relations in both the domain

and the codomain of the mapping  $f$ , more specifically,  $f$  is a *morphism* between the *fuzzy structures*  $\langle A, \approx_A \rangle$  and  $\langle B, \approx_B \rangle$  where, in addition,  $\langle A, \approx_A \rangle$  has a fuzzy preordering relation  $\rho_A$ . Firstly, we have to characterize when it is possible to endow  $B$  with the adequate structure (namely, enrich it to a fuzzy pre-ordered structure) and, then, construct a mapping  $g$  from  $B$  to  $A$  compatible with the fuzzy equivalence relations such that the pair  $(f, g)$  forms a Galois connection.

Although all the obtained results are stated in terms of the existence and construction of right adjoints (or residual mappings), they can be straightforwardly modified for the existence and construction of left adjoints (or residuated mappings). On the other hand, it is worth remarking that the construction developed in this paper can be extended to the different types of Galois connections (see [16]).

The core of the paper starts after introducing the preliminary notions on Galois connections between fuzzy preordered structures. Specifically, given a mapping  $f: \mathbb{A} \rightarrow B$  from a fuzzy preordered structure  $\mathbb{A}$  into a fuzzy structure  $\langle B, \approx_B \rangle$ , we characterize when it is possible to construct a fuzzy relation  $\rho_B$  that induces a suitable fuzzy preorder structure on  $B$  and such that there exists a mapping  $g: B \rightarrow \mathbb{A}$  such that the pair  $(f, g)$  constitutes a Galois connection. In the case of existence of right adjoint, it is worth remarking that the right adjoint need not be unique since, actually, its construction is given with several of degrees of freedom, in particular for extending the fuzzy ordering from the image of  $f$  to the entire codomain. Although a convenient extension has been given, our results do not imply that every right adjoint can be constructed in this way, and there may exist other constructions that are adequate as well. This is a first topic for future work.

Then, we follow the structure of [17] where we consider a mapping  $f: \langle A, \rho_A \rangle \rightarrow B$  (and  $\rho_A$  is a fuzzy relation satisfying reflexivity,  $\otimes$ -transitivity and the weakest form of antisymmetry, namely,  $\rho_A(a, b) = \rho_A(b, a) = \top$  implies  $a = b$ , for all  $a, b \in A$ ); a further step was given in [7] for the same case  $f: \langle A, \rho_A \rangle \rightarrow B$ , in which antisymmetry was dropped. Both cases above can be seen as fuzzy preordered structures, in the sense of this paper, just by considering the so-called symmetric kernel relation (the conjunction of  $\rho_A(a, b)$  and  $\rho_A(b, a)$ ); the relationship between these and other kinds of structures can be found in [35]. Summarizing, the problem



in [7] can be seen as constructing a right adjoint of a mapping  $f: \langle A, \rho_A \rangle \rightarrow B$  which involves the construction of  $\rho_B$ , whereas in this paper our problem is to find a right adjoint to a mapping  $f: \langle A, \approx_A, \rho_A \rangle \rightarrow \langle B, \approx_B \rangle$  in which the fuzzy equivalence  $\approx_B$  has to be preserved; therefore, the main result in [7] is not exactly a particular case. We have considered a fuzzy mapping as a morphism  $\langle A, \approx_A \rangle \rightarrow \langle B, \approx_B \rangle$  between fuzzy structures, adopting the approach of [12], while our long-term goal is to study fuzzy Galois connections constituted of truly fuzzy mappings.

In a few words, our approach is based on the canonical decomposition of Galois connections in our framework, followed by an analysis of conditions for the existence of the right adjoint. As a consequence of the canonical decomposition, we propose a two-step procedure for verifying the existence of the right adjoint in a constructive manner.

#### CONCLUSIONS AND FUTURE WORK

Galois connections have found applications in areas such as formal concept analysis, and in mathematical morphology where, respectively, the intent and extent operators, and the erosion and the dilation operations are required to form a Galois connection. The results presented in this work pave the way to build specific settings of mathematical morphology parameterized by a fixed candidate to be an erosion (or dilation) operator; and the same approach would also apply to the development of new settings of formal concept analysis. In general, the construction of new Galois connections is of interest in fields in which there are two approaches to certain reality and one has more information about one of them, since the existence of a Galois connection allows to retrieve the unknown information in the other approach. In this respect, we will explore the application of the obtained results in the area of compression of data (images, etc.) in which the existence of the right adjoint of a given compressing mapping might allow to recover as much information as possible.

Last but not least, it is worth to study the two following extensions: on the one hand, we could consider an even more general notion of fuzzy mapping, for instance that proposed in [9]; on the other hand, we could consider  $\mathbb{L}$ -valued sets as a suitable generalization of our fuzzy structures.

#### REFERENCES

- [1] R. Bělohlávek. Fuzzy Galois connections. *Mathematical Logic Quarterly*, 45(4):497–504, 1999.
- [2] R. Bělohlávek, B. De Baets and J. Konecny. Granularity of attributes in formal concept analysis. *Information Sciences*, 260:149–170, 2014.
- [3] R. Bělohlávek, B. De Baets, J. Outrata and V. Vychodil. Characterizing trees in concept lattices. *Int. J. of Uncertainty, Fuzziness and Knowledge-Based Systems*, 16:1–15, 2008.
- [4] R. Bělohlávek, B. De Baets, J. Outrata and V. Vychodil. Inducing decision trees via concept lattices. *Int. J. of General Systems*, 38:455–467, 2009.
- [5] R. Bělohlávek and P. Osíčka. Triadic fuzzy Galois connections as ordinary connections. *Fuzzy Sets and Systems*, 249:83–99, 2014.
- [6] I. Bloch. Fuzzy sets for image processing and understanding. *Fuzzy Sets and Systems*, 281:280–291, 2015.
- [7] I.P. Cabrera, P. Cordero, F. García-Pardo, M. Ojeda-Aciego, and B. De Baets. On the construction of adjunctions between a fuzzy preposet and an unstructured set. *Fuzzy Sets and Systems*, 320:81–92, 2017.
- [8] G. Ciobanu and C. Vaideanu. Similarity relations in fuzzy attribute-oriented concept lattices. *Fuzzy Sets and Systems*, 275:88–109, 2015.
- [9] M. Cirić, J. Ignjatović and S. Bogdanović. Uniform fuzzy relations and fuzzy functions. *Fuzzy Sets and Systems*, 160:1054–1081, 2009.
- [10] P. Cordero, M. Enciso, A. Mora, M. Ojeda-Aciego, and C. Rossi. Knowledge discovery in social networks by using a logic-based treatment of implications. *Knowledge-Based Systems*, 87:16–25, 2015.
- [11] B. De Baets, E. Kerre and M. Gupta. The fundamentals of fuzzy mathematical morphology. Part 1: Basic concepts. *Int. J. of General Systems*, 23:155–171, 1994.
- [12] M. Demirci. A theory of vague lattices based on many-valued equivalence relations—I: general representation results. *Fuzzy Sets and Systems*, 151:437–472, 2005.
- [13] K. Denecke, M. Erné, and S. L. Wismath. *Galois Connections and Applications*. Kluwer Academic Publishers, 2004.
- [14] Y. Djouadi and H. Prade. Interval-valued fuzzy Galois connections: Algebraic requirements and concept lattice construction. *Fundamenta Informaticae*, 99(2):169–186, 2010.
- [15] A. Frasca. Fuzzy Galois connections under weak conditions. *Fuzzy Sets and Systems*, 172(1):33–50, 2011.
- [16] F. García-Pardo, I.P. Cabrera, P. Cordero, and M. Ojeda-Aciego. On Galois connections and soft computing. *Lect. Notes in Computer Science*, 7903:224–235, 2013.
- [17] F. García-Pardo, I.P. Cabrera, P. Cordero, and M. Ojeda-Aciego. On the construction of fuzzy Galois connections. In *Proc. of the XVII Spanish Conf. on Fuzzy Logic and Technology*, 99–102, 2014.
- [18] F. García-Pardo, I.P. Cabrera, P. Cordero, M. Ojeda-Aciego and F.J. Rodríguez. On the definition of suitable orderings to generate adjunctions over an unstructured codomain. *Information Sciences*, 286:173–187, 2014.
- [19] G. Georgescu and A. Popescu. Non-commutative fuzzy Galois connections. *Soft Computing*, 7(7):458–467, 2003.
- [20] M. González-Hidalgo, S. Massanet, A. Mir and D. Ruiz-Aguilera. A fuzzy morphological hit-or-miss transform for grey-level images: A new approach. *Fuzzy Sets and Systems*, 286:30–65, 2016.
- [21] J. Gutiérrez-García, I. Mardones-Pérez, M. A. de Prada-Vicente, and D. Zhang. Fuzzy Galois connections categorically. *Mathematical Logic Quarterly*, 56(2):131–147, 2010.
- [22] J. Järvinen. Pawlak’s information systems in terms of Galois connections and functional dependencies. *Fund. Informaticae*, 75:315–330, 2007.
- [23] J. Konecny. Isotone fuzzy Galois connections with hedges. *Information Sciences*, 181(10):1804–1817, 2011.
- [24] J. Konecny and M. Krupka. Block relations in formal fuzzy concept analysis. *Intl. J. of Approximate Reasoning*, 73:27–55, 2016.
- [25] S. Kuznetsov. Galois connections in data analysis: Contributions from the Soviet era and modern Russian research. *Lect. Notes in Computer Science*, 3626:196–225, 2005.
- [26] S.-T. Li and F.-C. Tsai. A fuzzy conceptualization model for text mining with application in opinion polarity classification. *Knowledge-Based Systems*, 39:23–33, 2013.
- [27] T. Martin and A. Majidian. Finding fuzzy concepts for creative knowledge discovery. *Intl. J. of Intelligent Systems*, 28(1):93–114, 2013.
- [28] S.-C. Mu and J. Oliveira. Programming from Galois connections. *J. of Logic and Algebraic Programming*, 81(6):680–704, 2012.
- [29] J. Pócs. Note on generating fuzzy concept lattices via Galois connections. *Information Sciences*, 185(1):128–136, 2012.
- [30] J. Propp. A Galois connection in the social network. *Mathematics Magazine*, 85(1):34–36, 2012.
- [31] Y. Shi, M. Nachtegaal, D. Ruan and E. Kerre. Fuzzy adjunctions and fuzzy morphological operations based on implications. *Intl. J. of Intelligent Systems*, 24(12):1280–1296, 2009.
- [32] P. Sussner. Lattice fuzzy transforms from the perspective of mathematical morphology. *Fuzzy Sets and Systems*, 288:115–128, 2016.
- [33] M. Wolski. Galois connections and data analysis. *Fundamenta Informaticae*, 60:401–415, 2004.
- [34] W. Yao and L.-X. Lu. Fuzzy Galois connections on fuzzy posets. *Mathematical Logic Quarterly*, 55(1):105–112, 2009.
- [35] W. Yao. Quantitative domains via fuzzy sets. Part I: Continuity of fuzzy directed complete posets. *Fuzzy Sets and Systems*, 161:973–987, 2010.

# Operations between fuzzy multisets

Ángel Riesgo

*Dept. of Statistics and O.R.  
University of Oviedo  
Oviedo, Spain  
ariesgo@yahoo.com*

Pedro Alonso

*Dept. of Mathematics  
University of Oviedo  
Gijón, Spain  
palonso@uniovi.es*

Irene Díaz

*Dept. of Informatics  
University of Oviedo  
Oviedo, Spain  
sirene@uniovi.es*

Susana Montes

*Dept. of Statistics and O.R.  
University of Oviedo  
Oviedo, Spain  
montes@uniovi.es*

**Abstract**—For fuzzy multisets the membership values are multisets in  $[0, 1]$ . These sets are a mathematically generalization of the hesitant fuzzy sets, but in this general environment, the information about repetition is not lost, so that, the opinions given by the experts are better managed. Moreover, the order of the different opinions is also considered and this information is not lost either. In particular, we have studied in detail the basic operations for these sets: complement, union and intersection.

**Index Terms**—fuzzy multiset, complement, aggregated union, aggregated intersection.

## I. INTRODUCTION

Fuzzy sets were introduced by Lotfi A. Zadeh (see [7]) as a way to deal with real-life situations where there is either limited knowledge or some sort of implicit ambiguity about whether an element should be considered a member of a set. Thus, the membership degree for any element is a value in the real interval  $[0, 1]$ . However, it could be paradoxical that the membership value itself should be one precise real number. Then, different generalizations appeared as a way to solve this paradox. In that cases, the membership degree could be, for example, an interval (interval-valued fuzzy sets [2]), a function (type-2 fuzzy sets [2]) or an arbitrary subsets of  $[0, 1]$  (hesitant fuzzy sets [5]). When the subsets are finite, the hesitant fuzzy sets are called typical hesitant fuzzy sets and they are the ones that have attracted the most attention from researchers ([1], [3], [6]). However, for hesitant fuzzy sets the order of the elements in the set is not important and moreover, the repetition are not allowed. Clearly, this could be an important drawback. In fact, the need to account for repeated membership values has been recognised in the literature about hesitant fuzzy sets and, in fact, multiset-based hesitant fuzzy sets were already mentioned in the original paper that introduced the hesitant fuzzy sets [5]. Thus, fuzzy multisets can be considered as an appropriate tool to deal with repetitions. In that case, the membership degree is a multiset in the  $[0, 1]$  interval. But despite the similarities, we cannot regard the typical hesitant fuzzy sets as a particular case of the fuzzy multisets and neither can we identify the fuzzy multisets with the multiset-based hesitant fuzzy sets because the definitions for the intersection and union are different in each theory. In [4] we have established the appropriate mathematical definitions for the main operations for fuzzy

multisets and show how the hesitant theory definitions can be worked out from an extension of the fuzzy multiset definitions. The main concepts and results obtained in [4] are summarized in the next two sections.

## II. FUZZY MULTISSETS

As we mentioned in the introduction, the values that make up a hesitant element in a hesitant fuzzy set are typically the result of applying several criteria on membership. In a common use case, it is assumed that there are a number of “experts” or “decision-makers” for a hesitant fuzzy set who produce a membership value for each element in the universe. A problem with the hesitant fuzzy sets in the experts’ model is that the information about repetition is lost. For example, if there are five experts and four of them assign a membership value of 0.1 to an element whereas the fifth expert assigns the value 0.2, the hesitant element will be  $\{0.1, 0.2\}$ , regardless of the fact that 0.1 was four times more popular among the experts. This information loss can be avoided by using fuzzy multisets [3] (also called fuzzy bags [6]), which we are going to discuss now.

**Definition 2.1:** [3] Let  $X$  be the universe. A fuzzy multiset  $\hat{A}$  over  $X$  is characterized by a function  $\hat{A}: X \rightarrow \mathbb{N}^{[0,1]}$ . The family of all the fuzzy multisets over  $X$  is called the fuzzy power multiset over  $X$  and is denoted by  $\mathcal{FM}(X)$ .

**Example 2.2:** Say we have a single-element universe  $X = \{x\}$ . We can define a fuzzy multiset  $\hat{A}$  as  $\hat{A}(x) = \langle 0.1, 0.2, 0.2 \rangle$  in angular-bracket notation. Or in other words, using Definition 2.1, the element  $x$  is being mapped into a function  $Count_{\hat{A}(x)}: [0, 1] \rightarrow \mathbb{N}$  defined as  $Count_{\hat{A}(x)}(0.1) = 1$ ,  $Count_{\hat{A}(x)}(0.2) = 2$  and  $Count_{\hat{A}(x)}(t) = 0$  for any  $t \neq 0.1$  and  $t \neq 0.2$ . This function  $Count_{\hat{A}(x)}$  characterizes a crisp multiset for any  $x$  in  $X$ .

## III. OPERATIONS BETWEEN FUZZY MULTISSETS

The complement for the fuzzy multisets is quite intuitive.

**Definition 3.1:** [3] Let  $X$  be a universe and let  $\hat{A} \in \mathcal{FM}(X)$  be a fuzzy multiset. The complement of  $\hat{A}$  is the fuzzy multiset  $\hat{A}^c$  defined by the following count function:

$$Count_{\hat{A}^c(x)}(t) = Count_{\hat{A}(x)}(1 - t), \quad \forall x \in X, \quad \forall t \in [0, 1]$$

where  $Count: M \rightarrow \mathbb{N}$  mapping each element of the universe to a natural number (including 0).

This work was partially supported by the Spanish Ministry of Science and Technology under projects TIN2014-59543-P and TIN-2017-87600-P.



**Example 3.2:** If we have a two-element universe  $X = \{x, y\}$ , then a fuzzy multiset  $\hat{A}$  with  $\hat{A}(x) = \langle 0.3 \rangle$  and  $\hat{A}(y) = \langle 0.5, 0.8, 0.8 \rangle$  has the complement

$$\text{Count}_{\hat{A}^c(x)}(t) = \begin{cases} 1, & \text{if } t = 0.7, \\ 0, & \text{otherwise,} \end{cases}$$

$$\text{Count}_{\hat{A}^c(y)}(t) = \begin{cases} 1, & \text{if } t = 0.5, \\ 2, & \text{if } t = 0.2, \\ 0, & \text{otherwise,} \end{cases}$$

that is,  $\hat{A}^c(x) = \langle 0.7 \rangle$  and  $\hat{A}^c(y) = \langle 0.5, 0.2, 0.2 \rangle$ .

By taking the multiset union of all the combinations, we can define what we will call the aggregated intersection and union of two fuzzy multisets, which do not privilege any particular ordering.

**Definition 3.3:** Let  $X$  be a universe and let  $\hat{A}, \hat{B} \in \mathcal{FM}(X)$  be two fuzzy multisets. The aggregated intersection of  $\hat{A}$  and  $\hat{B}$  is a fuzzy multiset  $\hat{A} \cap^\alpha \hat{B}$  such that for any element  $x \in X$ ,  $\hat{A} \cap^\alpha \hat{B}(x)$  is the union, in the crisp multiset sense, of the regularised  $(s_A, s_B)$ -ordered intersections for all the possible pairs of ordering strategies  $(s_A, s_B)$ , that is,

$$\hat{A} \cap^\alpha \hat{B}(x) = \bigcup_{\substack{s_{\hat{A}} \in \mathcal{OS}(\hat{A}^r) \\ s_{\hat{B}} \in \mathcal{OS}(\hat{B}^r)}} \hat{A} \cap_{(s_A, s_B)}^r \hat{B}(x), \quad \forall x \in X.$$

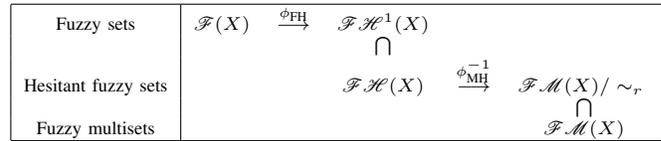
**Definition 3.4:** Let  $X$  be a universe and let  $\hat{A}, \hat{B} \in \mathcal{FM}(X)$  be two fuzzy multisets. The aggregated union of  $\hat{A}$  and  $\hat{B}$  is a fuzzy multiset  $\hat{A} \cup^\alpha \hat{B}$  such that for any element  $x \in X$ ,  $\hat{A} \cup^\alpha \hat{B}(x)$  is the union, in the crisp multiset sense, of the regularised  $(s_A, s_B)$ -ordered unions for all the possible pairs of ordering strategies  $(s_A, s_B)$ , that is,

$$\hat{A} \cup^\alpha \hat{B}(x) = \bigcup_{\substack{s_{\hat{A}} \in \mathcal{OS}(\hat{A}^r) \\ s_{\hat{B}} \in \mathcal{OS}(\hat{B}^r)}} \hat{A} \cup_{(s_A, s_B)}^r \hat{B}(x), \quad \forall x \in X.$$

**Example 3.5:** For two fuzzy multisets  $\hat{E}(x) = \langle 0.1, 0.4 \rangle$  and  $\hat{F}(x) = \langle 0.2, 0.3 \rangle$ , the Miyamoto intersection and union are  $\hat{E} \cap \hat{F}(x) = \langle 0.1, 0.3 \rangle$  and  $\hat{E} \cup \hat{F}(x) = \langle 0.2, 0.4 \rangle$ . In order to calculate their aggregated intersection and union, we need to first calculate the intersections and unions for all the possible ordering strategies. There are two possible ordering strategies for  $\hat{E}$ , resulting in the sequences  $(0.1, 0.4)$  and  $(0.4, 0.1)$ , and two possible ordering strategies for  $\hat{F}$ , resulting in the sequences  $(0.2, 0.3)$  and  $(0.3, 0.2)$ . This leads to the four sequences of pairwise minima,  $(0.1, 0.3)$ ,  $(0.1, 0.2)$ ,  $(0.2, 0.1)$ ,  $(0.3, 0.1)$ , which result in two ordered intersections,  $\langle 0.1, 0.3 \rangle$ ,  $\langle 0.1, 0.2 \rangle$ ; and to the four sequences of pairwise maxima,  $(0.2, 0.4)$ ,  $(0.3, 0.4)$ ,  $(0.4, 0.3)$ ,  $(0.4, 0.2)$ , which result in two ordered unions,  $\langle 0.2, 0.4 \rangle$ ,  $\langle 0.3, 0.4 \rangle$ . By taking the union, in the crisp multiset sense, we get the aggregated intersection and union:  $\hat{E} \cap^\alpha \hat{F}(x) = \langle 0.1, 0.2, 0.3 \rangle$  and  $\hat{E} \cup^\alpha \hat{F}(x) = \langle 0.2, 0.3, 0.4 \rangle$ . We have found the striking result that the numeric values match those of the hesitant fuzzy set intersection and union in the previous examples, a hint that the hesitant theory is equivalent to the fuzzy multiset theory

when the aggregated operations are used, as we will prove in the next section.

These definitions are coherent with the existing ones for hesitant fuzzy sets and fuzzy sets, which can be seen as particular cases of fuzzy multisets. These relations can be summed up in the following diagram:



### REFERENCES

- [1] B. Bedregal, G. Beliakov, H. Bustince, T. Calvo, R. Mesiar, D. Paternain, "A class of fuzzy multisets with a fixed number of memberships," *Information Sciences* 189, 2012, pp. 1–17.
- [2] G.J. Klir, B. Yuan, *Fuzzy Sets and Fuzzy Logic*. Prentice Hall P T R, 1995.
- [3] S. Miyamoto, "Fuzzy Multisets and Their Generalizations," in: C.S. Calude, G. Păun, G. Rozenberg, A. Salomaa (Eds), *Multiset Processing*. WMC 2000. Lecture Notes in Computer Science, Springer, Berlin, Heidelberg, 2000, pp. 225–235.
- [4] A. Riesgo, P. Alonso, I. Díaz, S. Montes, "Basic operations for fuzzy multisets," *International Journal of Approximate Reasoning* 101, (2018), pp. 107–118.
- [5] V. Torra, "Hesitant Fuzzy Sets," *International Journal of Intelligent Systems* 25 (6), 2010, pp. 529–539.
- [6] R.R. Yager, "On the theory of Bags," *International Journal of General Systems* 13 (1), 1986, pp. 23–37.
- [7] L.A. Zadeh, "Fuzzy Sets," *Information Control* 8 (3), 1965, pp. 338–353.

# Un marco semántico general para la Lógica de Simplificación

Pablo Cordero, Manuel Enciso, Angel Mora  
*Universidad de Málaga,*  
*Andalucía Tech.*  
 Málaga, Spain  
 {pcordero,enciso}@uma.es, amora@ctima.uma.es

Vilem Vychodil  
*Dept. Computer Science*  
*Palacky University Olomouc*  
 Olomouc, Czechia  
 vilem.vychodil@upol.cz

**Resumen**—Presentamos una generalización de la Lógica de Simplificación para el razonamiento con reglas “si-entonces” sobre atributos difusos. Las implicaciones y la lógica propuesta están parametrizadas por sistemas de conexiones de Galois isótonas que permiten manejar diferentes interpretaciones de dependencias entre datos. Describimos la semántica de las reglas y el sistema axiomático de la lógica.

**Index Terms**—Teoría de retículos, lógica difusa, implicaciones

## I. PARAMETRIZACIONES POR CONEXIONES DE GALOIS ISÓTONAS

En este trabajo resumimos el presentado en [9] que se enmarca dentro del Análisis Formal de Conceptos (AFC) [1] en su versión difusa. Ésta considera un retículo completo residuado  $\mathbb{L}$  y define un  $\mathbb{L}$ -contexto como una terna  $\mathbf{I} = \langle X, Y, I \rangle$  donde  $X$  e  $Y$  son conjuntos no vacíos de objetos y atributos respectivamente e  $I$  es una  $\mathbb{L}$ -relación difusa de  $X$  en  $Y$ . Para cada objeto  $x \in X$ , se considera el conjunto difuso  $I_x \in L^Y$  tal que  $I_x(y) = I(x, y)$  para todo  $y \in Y$ . Una implicación de atributos es una expresión  $A \Rightarrow B$  donde  $A, B \in L^Y$  y se dice que el contexto  $\mathbf{I}$  la satisface si  $A \subseteq I_x$  implica  $B \subseteq I_x$  para todo  $x \in X$ .

Nuestra propuesta explora sistemas de inferencia generales para razonar con implicaciones entre atributos difusos. Tomamos como punto de partida la generalización presentada en [3], donde el autor considera, como parámetros, un conjunto  $S$  de conexiones de Galois isótonas que es cerrado bajo composición y contiene a la identidad. Propone una axiomatización completa basada en los Axiomas de Armstrong. En este marco general, una implicación  $A \Rightarrow B$  es cierta en  $I_x$  si, para todo  $\langle \mathbf{f}, \mathbf{g} \rangle \in S$ , se cumple que  $\mathbf{f}(A) \subseteq I_x$  implica  $\mathbf{f}(B) \subseteq I_x$ .

Como alternativa a los bien conocidos Axiomas de Armstrong [7], en [8] los autores propusieron una Lógica de Simplificación y nuevos métodos para la manipulación automática de implicaciones [10], [11]. Posteriormente, en [4], se propuso la lógica FASL (*Fuzzy Attribute Simplification Logic*) para implicaciones de atributos con grados y parametrizados por “hedges”.

En este resumen mostramos una generalización de la Lógica de Simplificación, equivalente a la citada [3], para impli-

caciones con grados cuya semántica está parametrizada por conexiones de Galois isótonas.

## II. MARCO TEÓRICO

En este marco general, consideramos, como estructura para los grados, un retículo co-residuado completo, es decir, un álgebra  $\mathbb{L} = \langle L, \leq, \oplus, \ominus, 0, 1 \rangle$  satisfaciendo las siguientes condiciones:

- $\langle L, \leq, 0, 1 \rangle$  es un retículo completo donde 0 es el mínimo y 1 es el máximo. Como es usual, usamos los símbolos  $\vee$  y  $\wedge$  para denotar respectivamente supremo e ínfimo.
- $\langle L, \oplus, 0 \rangle$  es un monoide conmutativo.
- El par  $\langle \oplus, \ominus \rangle$  satisface la siguiente propiedad de adjunción: para todo  $a, b, c \in L$ ,

$$a \leq b \oplus c \quad \text{si y solo si} \quad a \ominus b \leq c. \quad (1)$$

$L^Y$  denota el conjunto de todos los  $\mathbb{L}$ -conjuntos difusos en el universo  $Y$ . Las operaciones en  $\mathbb{L}$  se extienden elemento a elemento a los  $\mathbb{L}$ -conjuntos difusos en la forma habitual: Para  $A, B \in L^Y$  los  $\mathbb{L}$ -conjuntos difusos  $A \oplus B$  and  $A \ominus B$  se definen como  $(A \oplus B)(y) = A(y) \oplus B(y)$  y  $(A \ominus B)(y) = A(y) \ominus B(y)$  para todo  $y \in Y$ .

Las parametrizaciones [3] que se usan en nuestra propuesta se definen en términos de conexiones de Galois isótonas en  $\langle L^Y, \subseteq \rangle$ . En particular, consideramos pares  $\langle \mathbf{f}, \mathbf{g} \rangle$  donde  $\mathbf{f}, \mathbf{g}: L^Y \rightarrow L^Y$  son tales que, para todo  $A, B \in L^Y$ ,

$$\mathbf{f}(A) \subseteq B \quad \text{si y solo si} \quad A \subseteq \mathbf{g}(B). \quad (2)$$

Es bien conocido que esta definición es equivalente a pedir que ambas funciones sean isótonas, que  $\mathbf{g} \circ \mathbf{f}$  se inflacionaria y que  $\mathbf{f} \circ \mathbf{g}$  sea deflacionaria. Como consecuencia,  $\mathbf{g} \circ \mathbf{f}$  es un *operador de cierre* y  $\mathbf{f} \circ \mathbf{g}$  es un *operador de núcleo* (*operador interior*).

Además, para cualquier isomorfismo  $\mathbf{f}$  in  $\langle L^Y, \subseteq \rangle$ , el par  $\langle \mathbf{f}, \mathbf{f}^{-1} \rangle$  es una conexión de Galois isótona y, en particular, la función identidad  $\mathbf{I}_Y: L^Y \rightarrow L^Y$  lo es. Otro ejemplo interesante es  $\langle \mathbf{0}_Y, \mathbf{1}_Y \rangle$  donde  $\mathbf{0}_Y(A)(y) = 0$  y  $\mathbf{1}_Y(A)(y) = 1$ , para cualquier  $A \in L^Y$  e  $y \in Y$ .

Por último, dadas dos conexiones de Galois isótonas  $\langle \mathbf{f}_1, \mathbf{g}_1 \rangle$  y  $\langle \mathbf{f}_2, \mathbf{g}_2 \rangle$ , su *composición*  $\langle \mathbf{f}_1 \circ \mathbf{f}_2, \mathbf{g}_2 \circ \mathbf{g}_1 \rangle$  es también una conexión de Galois.

Supported by Grants TIN2014-59471-P and TIN2017-89023-P. V. Vychodil was also supported the project no. CZ.1.07/2.3.00/20.0059.



**Definición 1** ([3]): Una familia de conexiones de Galois isotonas  $S$  in  $\langle L^Y, \subseteq \rangle$  es una  $\mathbb{L}$ -parametrización si  $\mathbb{S} = \langle S, \circ, \langle \mathbf{I}_Y, \mathbf{I}_Y \rangle \rangle$  es un monoide. En otras palabras, si  $S$  es es cerrada para la composición y contiene a la identidad.

### III. LÓGICA DE SIMPLIFICACIÓN PARAMETRIZADA

Dado un alfabeto  $Y$  no vacío, cuyos elementos se denominan *atributos*, el conjunto de fórmulas bien formadas del lenguaje es:

$$\mathcal{L}_Y = \{A \Rightarrow B \mid A, B \in L^Y\}.$$

Las fórmulas del lenguaje se denominan *implicaciones* y para cada implicación, la primera y segunda componente se denomina *premisa* y *conclusión* respectivamente. Finalmente, los conjuntos de implicaciones  $\Sigma \subseteq \mathcal{L}$  se denominan *teorías*.

Sobre este lenguaje, definimos la Lógica de Simplificación presentando la semántica y un sistema axiomático. Finalmente, en la publicación de referencia del presente resumen [9], se prueba que la visión semántica y sintáctica coinciden, probando la corrección y completitud de la lógica propuesta.

Antes de definir la interpretación de las fórmulas, introducimos el concepto de  $\mathbb{L}$ -conjuntos difusos  $S$ -aditivos que juegan un papel fundamental en los modelos.

**Definición 2:** Sea  $Y$  un conjunto no vacío y  $S$  una  $\mathbb{L}$ -parametrización. Un  $\mathbb{L}$ -conjunto difuso  $A \in L^Y$  se dice  $S$ -aditivo si, para todo  $B, C \in L^Y$  y  $\langle \mathbf{f}, \mathbf{g} \rangle \in S$ ,

$$\mathbf{f}(B) \subseteq A \text{ y } \mathbf{f}(C) \subseteq A \text{ implica } \mathbf{f}(B \oplus C) \subseteq A.$$

La proposición siguiente es directa a partir de la Definición 2 y (2).

**Proposición 1:** Sea  $Y$  un conjunto no vacío y  $S$  una  $\mathbb{L}$ -parametrización. Un  $\mathbb{L}$ -conjunto difuso  $A \in L^Y$  es  $S$ -aditivo si y solo si  $\mathbf{g}(A) \oplus \mathbf{g}(A) = \mathbf{g}(A)$ .

Dada una  $\mathbb{L}$ -parametrización  $S$ , los modelos de la lógica se definen en términos de  $\mathbb{L}$ -conjuntos  $S$ -aditivos de la siguiente forma:

**Definición 3:** Sea  $A \Rightarrow B \in \mathcal{L}_Y$ . Un conjunto  $S$ -aditivo  $M \in L^Y$  es un *modelo* para  $A \Rightarrow B$  si, para todo  $\langle \mathbf{f}, \mathbf{g} \rangle \in S$ ,  $\mathbf{f}(A) \subseteq M$  implica que  $\mathbf{f}(B) \subseteq M$ .

Denotamos el conjunto de los modelos de  $A \Rightarrow B$  por  $\text{Mod}(A \Rightarrow B)$ . De forma usual, el conjunto de modelos para una teoría  $\Sigma \subseteq \mathcal{L}_Y$  se define como

$$\text{Mod}(\Sigma) = \bigcap_{A \Rightarrow B \in \Sigma} \text{Mod}(A \Rightarrow B).$$

Por extensión, un  $\mathbb{L}$ -contexto  $\mathbf{I} = \langle X, Y, I \rangle$  es un modelo de  $A \Rightarrow B$  cuando  $\{I_x \mid x \in X\} \subseteq \text{Mod}(A \Rightarrow B)$ .

**Definición 4:** Sea  $A \Rightarrow B \in \mathcal{L}_Y$  y  $\Sigma \subseteq \mathcal{L}_Y$ . La implicación  $A \Rightarrow B$  se dice *semánticamente derivada* de la teoría  $\Sigma$ , denotado por  $\Sigma \models A \Rightarrow B$ , si  $\text{Mod}(\Sigma) \subseteq \text{Mod}(A \Rightarrow B)$ .

Introducimos por último en el presente resumen el sistema axiomático de la lógica.

**Definición 5:** El sistema axiomático está formado por un esquema de axioma y tres reglas de inferencia:

*Reflexividad:* infiere  $A \Rightarrow A$ ,

*Composición:* de  $A \Rightarrow B, A \Rightarrow C$  infiere  $A \Rightarrow B \oplus C$ ,

*Simplificación:* de  $A \Rightarrow B, C \Rightarrow D$  infiere  $A \oplus (C \ominus B) \Rightarrow D$ ,

*Extensión:* de  $A \Rightarrow B$  infiere  $\mathbf{f}(A) \Rightarrow \mathbf{f}(B)$ .

para todo  $A, B, C, D \in L^Y$  y  $\langle \mathbf{f}, \mathbf{g} \rangle \in S$ .

Del modo habitual, se dice que una implicación  $A \Rightarrow B \in \mathcal{L}_Y$  es sintácticamente derivada de (o inferida por) una teoría  $\Sigma \subseteq \mathcal{L}_Y$ , denotado por  $\Sigma \vdash A \Rightarrow B$ , si existe una secuencia  $\sigma_1, \dots, \sigma_n \in \mathcal{L}_Y$  tal que  $\sigma_n$  es  $A \Rightarrow B$  y, para todo  $1 \leq i \leq n$ , una de las siguientes condiciones se cumple:

- $\sigma_i \in \Sigma$ ;
- $\sigma_i$  es un axioma (Reflexividad);
- $\sigma_i$  se obtiene aplicando reglas de inferencia (Composición, Simplificación o Extensión) a implicaciones de  $\{\sigma_j \mid 1 \leq j < i\}$ .

El siguiente teorema asegura que ambos pilares de la lógica, las derivaciones semánticas y sintácticas, coinciden.

**Teorema 1 (Corrección y completitud):** Para cualquier implicación  $A \Rightarrow B \in \mathcal{L}_Y$  y cualquier teoría  $\Sigma \subseteq \mathcal{L}_Y$ , las siguientes afirmaciones se cumplen:

1.  $\Sigma \vdash A \Rightarrow B$  implica  $\Sigma \models A \Rightarrow B$ .
2. Si  $L^Y$  es finito,  $\Sigma \models A \Rightarrow B$  implica  $\Sigma \vdash A \Rightarrow B$ .

### REFERENCIAS

- [1] Ganter, B., Wille, R.: Formal Concept Analysis: Mathematical Foundations. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 1st edn. (1997)
- [2] Belohlavek, R.: Fuzzy Relational Systems: Foundations and Principles. Kluwer Academic Publishers, Norwell, MA, USA (2002)
- [3] Vychodil, V.: Parameterizing the semantics of fuzzy attribute implications by systems of isotone Galois connections. IEEE Trans. on Fuzzy Systems 24, 645–660 (2016)
- [4] Belohlavek, R., Cordero, P., Enciso, M., Mora, A., Vychodil, V.: Automated prover for attribute dependencies in data with grades. International Journal of Approximate Reasoning 70, 51–67 (2016)
- [5] Belohlavek, R., Vychodil, V.: Attribute dependencies for data with grades I. International Journal of General Systems 45(7–8), 864–888 (2016)
- [6] Belohlavek, R., Vychodil, V.: Attribute dependencies for data with grades II. International Journal of General Systems 46(1), 66–92 (2017)
- [7] Armstrong, W.W.: Dependency structures of data base relationships. In: Rosenfeld, J.L., Freeman, H. (eds.) Information Processing 74: Proceedings of IFIP Congress. pp. 580–583. North Holland, Amsterdam (1974)
- [8] Cordero, P., Enciso, M.M., Mora, A., de Guzmán, I.P.I., Mora, Á., Pérez de Guzman, I.: SLFD Logic: Elimination of Data Redundancy in Knowledge Representation 2527, 141–150 (2002)
- [9] Cordero, P., Enciso, M., Mora, A., Vychodil, V.: Towards Simplification Logic for Graded Attribute Implications with General Semantics. CEUR Workshop Proceedings, 2123: 129–140, 2018. Selected papers of the 14th International Conference on Concept Lattices and Their Applications. ISSN: 1613-0073. <http://ceur-ws.org/Vol-2123/>
- [10] Lorenzo, E.R., Adaricheva, K.V., Cordero, P., Enciso, M., Mora, A.: From an Implicational System to its Corresponding D-basis. In: Proceedings of the Twelfth International Conference on Concept Lattices and Their Applications, Clermont-Ferrand, France, October 13-16, 2015. pp. 217–228 (2015)
- [11] Mora, A., Cordero, P., Enciso, M., Fortes, I., Aguilera, G.: Closure via functional dependence simplification. International Journal of Computer Mathematics 89(4), 510–526 (2012)



# **XIX Congreso Español sobre Tecnologías y Lógica Fuzzy (XIX ESTYLF)**

**ESTYLF 9: SESIÓN ESPECIAL:  
APLICACIONES DE  
FUNCIONES DE AGREGACIÓN  
Y PRE-AGREGACIÓN**

**Organizadores:**

HUMBERTO BUSTINCE, TOMASA CALVO,  
JAVIER FERNÁNDEZ, LAURA DE MIGUEL







# Condiciones de monotonía direccional: interpretación geométrica

1<sup>st</sup> Laura De Miguel

*Departamento de Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, Spain  
laura.demiguel@unavarra.es

2<sup>nd</sup> Mikel Sesma-Sara

*Departamento de Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, Spain  
mikel.sesma@unavarra.es

3<sup>rd</sup> Antonio Roldán

*Departamento de Didáctica de la Matemática*  
*Universidad de Granada*  
Granada, Spain  
aroldan@ugr.es

4<sup>th</sup> Julio Lafuente,

*Departamento de Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, Spain  
lafuente@unavarra.es

5<sup>th</sup> Radko Mesiar

*Department of Mathematics and Descriptive Geometry*  
*Slovak University of Technology in Bratislava*  
Bratislava, Slovak Republic  
mesiar@math.sk

6<sup>th</sup> Humberto Bustince

*Departamento de Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, Spain  
bustince@unavarra.es

**Abstract**—En los últimos años ha habido un gran interés en estudiar condiciones de monotonía menos restrictivas para construir nuevas familias de funciones de fusión de datos. Varias de estas condiciones son la monotonía débil, la monotonía direccional, la monotonía direccional ordenada, y la monotonía direccional ordenada reforzada. En este trabajo presentamos algunos resultados sobre las monotonías anteriores desde el punto de vista de la geometría en dos dimensiones.

**Index Terms**—Funciones de agregación, condiciones de monotonía, geometría bidimensional

## I. INTRODUCCIÓN

La cantidad de aparatos inteligentes y sensores que nos rodea ha crecido exponencialmente en los últimos años lo que conlleva que cada vez tenemos mayor volumen de datos de todo tipo y naturaleza. Debido al prácticamente inmanejable volumen de datos, la necesidad de encontrar operadores apropiados para fusionar los datos de acuerdo a la aplicación considerada es más importante cada día.

Desde sus inicios, las funciones de agregación han jugado un papel crucial en varias y diversas aplicaciones [1]–[4]. Además, dependiendo del tipo de propiedades que se impongan a las funciones de agregación (véase [5] para más información), distintas clases de funciones han sido definidas en la literatura: t-normas/t-conormas [6], uninormas [7] o funciones de solapamiento (*overlap functions*) [8], entre otras.

Este trabajo ha sido financiado por el Servicio de Investigación de la Universidad Pública de Navarra y por el proyecto TIN2016-77356-P del MINECO, AEI/FEDER, UE y por el proyecto APVV-14-0013.

La condición de monotonía impuesta a las funciones de agregación juega un papel muy importante en aplicaciones como la toma de decisión donde el aumento de un valor (que significa que un criterio o una alternativa es mejor) no debe nunca implicar un descenso de la puntuación final o utilidad. Sin embargo, en otro tipo de aplicaciones, en especial en áreas donde es frecuente la aparición de *outliers* o datos afectados por diversos ruidos, la monotonía impuesta en cada argumento es un inconveniente en vez de una ventaja. Esto demuestra, que para algunos casos particulares de aplicación, la condición de monotonía que satisfacen las funciones de agregación, es decir, el crecimiento en cada argumento de la función puede ser demasiado restrictiva y a veces no es necesario que las funciones cumplan una condición tan fuerte para dar unos buenos resultados.

Teniendo en cuenta todas las consideraciones anteriores sobre las funciones de agregación, en la literatura reciente, encontramos diversos esfuerzos de definir y estudiar diversas condiciones de monotonía menos restrictivas. La monotonía débil [9], la monotonía direccional [10], la monotonía direccional ordenada [11] y la monotonía direccional ordenada reforzada son algunos ejemplos de nuevas condiciones de monotonía que generan nuevas clases de operadores de fusión de datos. Estas nuevas nociones de monotonía han sido aplicados en diversas aplicaciones como la clasificación o procesamiento de imagen. Por ejemplo, funciones de pre-agregación [12], que solo satisfacen monotonías direccionales han demostrado mejorar los resultados en algunos problemas de clasificación [13], mientras que las monotonías or-

denadas direccionales han demostrado mejorar los resultados en detección de bordes [11], [14] y extracción de características [15].

Todos los trabajos en los que se introducen las distintas nociones de monotonía trabajan estos conceptos desde un punto de vista formal dentro del análisis matemático. En este trabajo, con el propósito de conseguir una mejor comprensión de las distintas condiciones, así como sus diferencias nos centramos en la interpretación geométrica de las distintas condiciones de monotonía introducidas en la literatura reciente [9]–[11], [16]. Para ello, nos centramos en el caso de las funciones 2-dimensionales, cuyo conjunto dominio es el  $[0, 1]^2$  (representable en el plano). Las ventajas de esta aproximación son claras, ya que nos permite descubrir gráficamente el comportamiento de cada noción de monotonía descrita en los trabajos anteriores.

El artículo está organizado como sigue. En la Sección II, recordamos las diferentes nociones de monotonía (restringidas al caso 2-dimensional) a la vez que fijamos algunas notaciones. En la Sección III, estudiamos la interpretación geométrica de las distintas nociones centrándonos en la monotonía direccional ordenada y monotonía direccional ordenada reforzada, probando algunos resultados sobre el comportamiento de estas funciones en el caso 2-dimensional. En la Sección IV, acabamos con algunas conclusiones y trabajo a futuro.

## II. CONDICIONES DE MONOTONÍA

En este trabajo nos centramos en la representación geométrica de algunas nociones de monotonía definidas en la literatura reciente. Por claridad y sencillez de los resultados nos restringimos al caso 2-dimensional, pero es importante resaltar que las definiciones originales, que podemos encontrar en los trabajos [9]–[11], [16] están introducidas para el caso  $n$ -dimensional.

Consideramos vectores  $\vec{r} = (r_1, r_2) \in \mathbb{R}^2$  y puntos en el plano  $x = (x_1, x_2) \in [0, 1]^2$  ordenados según el orden parcial heredado de  $\mathbb{R}^2$  que viene dado por  $x = (x_1, x_2) \leq y = (y_1, y_2)$  si y solo si  $x_1 \leq x_2$  y  $y_1 \leq y_2$ . Sea  $S = \{\sigma_1 = (1, 2), \sigma_2 = (2, 1)\}$  el conjunto de permutaciones en dos dimensiones. Dados los elementos  $x \in [0, 1]^2$  y  $\vec{r} \in \mathbb{R}^2$ , el elemento  $x_{\sigma_i}$  representa el punto en el plano ordenado según la permutación  $x_{\sigma_i} = (x_{\sigma_i(1)}, x_{\sigma_i(2)})$  mientras que  $\vec{r}_{\sigma_i}$  representa el vector ordenado  $\vec{r}_{\sigma_i} = (r_{\sigma_i(1)}, r_{\sigma_i(2)})$ .

Las funciones de agregación son una clase de funciones de fusión a las que se les impone la condición de monotonía con respecto a cada argumento así como condiciones frontera en el 0 y en el 1. La definición de las funciones de agregación 2-dimensionales es la siguiente.

*Definición 2.1:* ([17], [18]) Una función  $A : [0, 1]^2 \rightarrow [0, 1]$  se llama una función de agregación si satisface la siguientes propiedades:

- $A(0, 0) = 0$
- $A(1, 1) = 1$
- $A(x_1, x_2) \leq A(y_1, y_2)$  para todo par de puntos  $x = (x_1, x_2), y = (y_1, y_2) \in [0, 1]^2$  tales que  $x_1 \leq y_1$  y  $x_2 \leq y_2$ .

Aunque las agregaciones han demostrado ser muy útiles en diversas aplicaciones, algunos operadores muy conocidos, como las medias Lehmer o la moda no cumplen las monotonía exigida a las funciones de agregación. Es por ello, que estudios recientes han intentado estudiar funciones de fusión con condiciones menos restrictivas para poder estudiar clases de funciones de fusión más generales. Algunas de estas condiciones menos restrictivas son la monotonía direccional, la monotonía direccional ordenada y la monotonía direccional ordenada reforzada. A continuación recordamos estas condiciones de monotonía para el caso de funciones 2-dimensionales.

*Definición 2.2:* ([9]): Una función  $F : [0, 1]^2 \rightarrow [0, 1]$  se dice débilmente creciente si la siguiente desigualdad se satisface

$$F(x_1 + c, x_2 + c) \geq F(x_1, x_2)$$

para todo  $(x_1, x_2) \in [0, 1]^2$  y  $c \in [0, 1]$  tal que  $(x_1, x_2) + (c, c) \in [0, 1]^2$ .

*Definición 2.3* ([10]): Sea  $\vec{r} = (r_1, r_2)$  un vector real 2-dimensional distinto del nulo. Una función  $F : [0, 1]^2 \rightarrow [0, 1]$  se dice  $\vec{r}$ -creciente si para todo punto  $(x_1, x_2) \in [0, 1]^2$  y para todo  $c > 0$  tales que  $(x_1 + cr_1, x_2 + cr_2) \in [0, 1]^2$  se cumple la siguiente condición

$$F(x_1 + cr_1, x_2 + cr_2) \geq F(x_1, x_2).$$

*Definición 2.4* ([11]): Sea  $\vec{r} = (r_1, r_2)$  un vector real 2-dimensional distinto del nulo. Una función  $F : [0, 1]^2 \rightarrow [0, 1]$  se dice  $\vec{r}$ -creciente Ordenada Direccional (OD) si para todo  $(x_1, x_2) \in [0, 1]^2$ , y para cada permutación  $\sigma \in S$  tal que  $x_{\sigma(1)} \geq x_{\sigma(2)}$  y para cualquier  $c > 0$  que cumple

$$1 \geq x_{\sigma(1)} + cr_1 \geq x_{\sigma(2)} + cr_2 \geq 0, \quad (1)$$

se cumple que

$$F(x_1 + cr_{\sigma^{-1}(1)}, x_2 + cr_{\sigma^{-1}(2)}) \geq F(x_1, x_2).$$

*Definición 2.5* ([16]): Sea  $\vec{r} = (r_1, r_2)$  un vector real 2-dimensional distinto del nulo. Una función  $F : [0, 1]^2 \rightarrow [0, 1]$  se dice  $\vec{r}$ -creciente ordenada direccional reforzada (SOD, del inglés *Strengthened Ordered Directional*) si para todo  $(x_1, x_2) \in [0, 1]^2$ , y para cada permutación  $\sigma \in S$  tal que  $x_{\sigma(1)} \geq x_{\sigma(2)}$  y para cualquier  $c > 0$  que cumple  $(x_{\sigma(1)} + cr_1, x_{\sigma(2)} + cr_2) \in [0, 1]^2$ , se satisface la siguiente inecuación

$$F(x_1 + cr_{\sigma^{-1}(1)}, x_2 + cr_{\sigma^{-1}(2)}) \geq F(x_1, x_2),$$

Si una función  $F$  es  $\vec{r}$ -creciente SOD, entonces  $F$  es también  $\vec{r}$ -creciente OD. El contrario no se cumple en general. Sin embargo, si el vector  $\vec{r}$  satisface  $r_1 \geq r_2$ , entonces ambas definiciones son equivalentes.

Nótese que por sencillez solo nos hemos referido a las condiciones de crecimiento, pero condiciones similares pueden ser introducidas para el decrecimiento de las funciones.

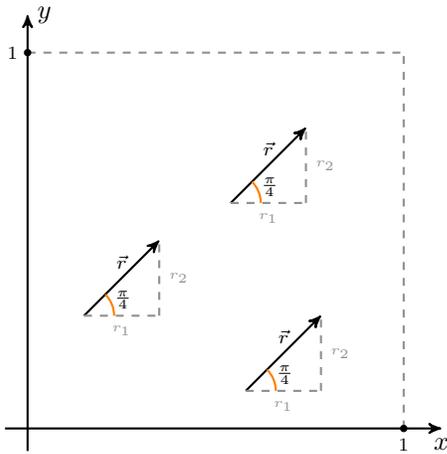


Fig. 1. Ejemplo de la dirección de una función débilmente creciente.

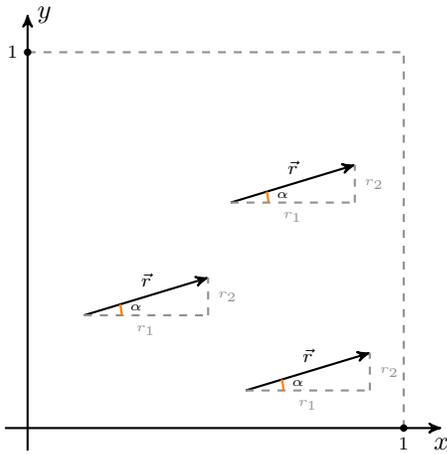


Fig. 2. Ejemplo de dirección de una función  $\vec{r}$ -creciente.

### III. INTERPRETACIÓN GEOMÉTRICA DE LAS CONDICIONES DE MONOTONÍA EN DOS DIMENSIONES

Una función débilmente creciente puede entenderse como una función que en cada punto del plano crece en la dirección  $(1,1)$ , es decir, crece a través de la recta que pasa por este punto en la dirección del vector  $(1,1)$  (véase Fig. 1). De manera similar, un función  $\vec{r} = (r_1, r_2)$ -creciente puede entenderse como una función que en cada punto del plano crece en la dirección  $(r_1, r_2)$ , es decir, crece a través de la recta que pasa por ese punto en la dirección del vector  $(r_1, r_2)$  (véase Fig. 2).

Tanto en el caso de las funciones débilmente crecientes como en el de las funciones  $\vec{r}$ -crecientes para un vector fijo  $\vec{r}$ , la dirección de la recta sobre la que crece está prefijada y es igual para todos los puntos del dominio. Por el contrario, la mayor diferencia entre las funciones anteriores y las funciones  $\vec{r}$ -crecientes OD y SOD se debe a que la dirección varía de una región a otra. En particular, si  $(x_1, x_2) \in [0, 1]^2$  y  $\sigma \in \mathcal{S}_n$  es la permutación que cumple  $x_{\sigma(1)} \geq x_{\sigma(2)}$ , entonces la reordenación de las componentes del vector  $\vec{r}_{\sigma^{-1}}$  en las

Definiciones 2.4 y 2.5 significa que la primera componente del vector,  $r_1$ , afecta al mayor valor de  $x$ , mientras que  $r_2$  afecta al menor de los valores de  $x$ . Esto significa que diferentes direcciones son consideradas dependiendo de la permutación que ordene las componentes del punto  $x$ . Formalicemos esta idea.

Dado que estamos trabajando únicamente en el caso 2-dimensional, dado un punto  $x = (x_1, x_2) \in [0, 1]^2$  se satisface que  $x_1 \leq x_2$  o  $x_2 \leq x_1$ . Esto significa que podemos diferenciar dos regiones de direcciones distintas.

Denotemos  $\Omega_1$  y  $\Omega_2$  a los subespacios

$$\Omega_1 = \{(x_1, x_2) \in [0, 1]^2 \mid x_1 \geq x_2\} \quad (2)$$

and

$$\Omega_2 = \{(x_1, x_2) \in [0, 1]^2 \mid x_1 \leq x_2\}. \quad (3)$$

Así mismo, denotamos por  $\Delta$  a la diagonal del espacio, que está formada por todos los puntos del plano que pertenecen a los dos espacios, es decir

$$\Delta = \Omega_1 \cap \Omega_2 = \{(x_1, x_2) \in [0, 1]^2 \mid x_1 = x_2\}.$$

*Proposición 3.1:* Sea  $\vec{r} = (r_1, r_2) \in \mathbb{R}^2$  un vector 2-dimensional distinto del nulo. La función  $F: [0, 1]^2 \rightarrow [0, 1]$  es  $\vec{r}$ -creciente SOD si y solo si

- para todo  $(x_1, x_2) \in \Omega_1$ ,  $F$  es  $(r_1, r_2)$ -creciente en  $(x_1, x_2)$ ;
- para todo  $(x_1, x_2) \in \Omega_2$ ,  $F$  es  $(r_2, r_1)$ -creciente en  $(x_1, x_2)$ .

Además, también se conocen los ángulos (con respecto al eje horizontal positivo) de las direcciones de crecimiento.

*Proposición 3.2:* Sea  $F: [0, 1]^2 \rightarrow [0, 1]$  una función  $\vec{r}$ -creciente SOD para un vector fijo  $\vec{r} = (r_1, r_2) \in \mathbb{R}^2$  no nulo. Se cumple que

- para todo  $(x_1, x_2) \in \Omega_1$ , el ángulo de la recta (con respecto al eje horizontal positivo) a través de la cuál la función  $F$  crece en el punto  $(x_1, x_2)$  es el siguiente:
  - si  $r_1 \geq 0$ , entonces  $\alpha = \arctan(\frac{r_2}{r_1})$  (véase nota a pie de página <sup>1</sup>).
  - si  $r_1 < 0$ , entonces  $\alpha = \pi + \arctan(\frac{r_2}{r_1})$ .
- para todo  $(x_1, x_2) \in \Omega_2$ , el ángulo de la recta (con respecto al eje horizontal positivo) a través de la cuál la función  $F$  crece en el punto  $(x_1, x_2)$  es el siguiente:
  - si  $r_2 \geq 0$ , entonces  $\beta = \arctan(\frac{r_1}{r_2})$ ;
  - si  $r_2 < 0$ , entonces  $\beta = \pi + \arctan(\frac{r_1}{r_2})$ .

Además, es fácil comprobar que se cumple  $\beta + \alpha = \frac{\pi}{2}$ .

*Demostración:* Sea  $(x_1, x_2) \in \Omega_1$ . Esto significa que  $x_1 \geq x_2$  y, por lo tanto, la permutación identidad  $\sigma_1$ , dada por  $\sigma_1(1) = 1$  y  $\sigma_1(2) = 2$ , satisface que  $x_{\sigma_1(1)} \geq x_{\sigma_1(2)}$ . Entonces, la dirección de crecimiento en el punto  $x$  es  $\vec{r} = (r_1, r_2)$  y, por lo tanto, el ángulo con respecto al eje horizontal positivo es  $\alpha = \arctan(\frac{r_2}{r_1})$  para todo vector  $\vec{r}$  tal que  $r_1 \geq 0$  y  $\alpha = \pi + \arctan(\frac{r_2}{r_1})$  para todo vector  $\vec{r}$  tal que  $r_1 < 0$ . De manera análoga, sea  $(x_1, x_2) \in \Omega_2$ . Esto

<sup>1</sup>Por convenio consideramos  $\arctan \frac{a}{0} = \text{sign}(a) \frac{\pi}{2}$ .

significa que  $x_2 \geq x_1$  y, por lo tanto, la permutación  $\sigma_2$ , dada por  $\sigma_2(1) = 2$  y  $\sigma_2(2) = 1$ , satisface que  $x_{\sigma_2(1)} \geq x_{\sigma_2(2)}$ . Entonces, la dirección de crecimiento en el punto  $x$  es  $\vec{r} = (r_{\sigma_2^{-1}(1)}, r_{\sigma_2^{-1}(2)}) = (r_2, r_1)$  y, por lo tanto, el ángulo con respecto al eje horizontal positivo es  $\beta = \arctan(\frac{r_1}{r_2})$  para todo vector  $\vec{r}$  tal que  $r_2 \geq 0$  y  $\beta = \pi + \arctan(\frac{r_1}{r_2})$  para todo vector  $\vec{r}$  tal que  $r_2 < 0$ .

La igualdad  $\alpha + \beta = \frac{\pi}{2}$  se cumple por el hecho de que para  $a \neq 0$ , se cumple  $\arctan(\frac{1}{a}) = \text{sign}(a)\frac{\pi}{2} - \arctan(a)$ . Nótese que algunas veces, el valor de la suma real es  $\frac{5\pi}{2}$ , pero este es el mismo ángulo que  $\frac{\pi}{2}$ . ■

*Nota 1:* Nótese que debido a que los elementos de la diagonal  $\Delta$  pertenecen tanto a  $\Omega_1$  como a  $\Omega_2$  ambas direcciones de crecimiento son impuestas.

Resultados similares pueden ser formulados para el caso de las funciones  $\vec{r}$ -crecientes OD en los que se impone el crecimiento solo al segmento formado de puntos de la recta que pertenecen al mismo conjunto  $\Omega_i$  que el punto inicial  $x$ .

*Corolario 3.3:* Sea  $\vec{0} \neq \vec{r} \in \mathbb{R}^2$ . Una función  $F: [0, 1]^2 \rightarrow [0, 1]$  es  $\vec{r}$ -creciente OD si y solo si

- para todo  $(x_1, x_2) \in \Omega_1$ ,  $F$  es  $(r_1, r_2)$ -creciente en  $(x_1, x_2)$  restringido al subconjunto  $\Omega_1$ ;
- para todo  $(x_1, x_2) \in \Omega_2$ ,  $F$  es  $(r_2, r_1)$ -creciente en  $(x_1, x_2)$  restringido al subconjunto  $\Omega_2$ .

Además, los ángulos de las rectas de crecimiento son los mismos que el caso de las funciones  $\vec{r}$ -crecientes SOD.

En el trabajo [16] puede encontrarse el siguiente resultado sobre la monotonía  $\vec{r}$ -creciente SOD.

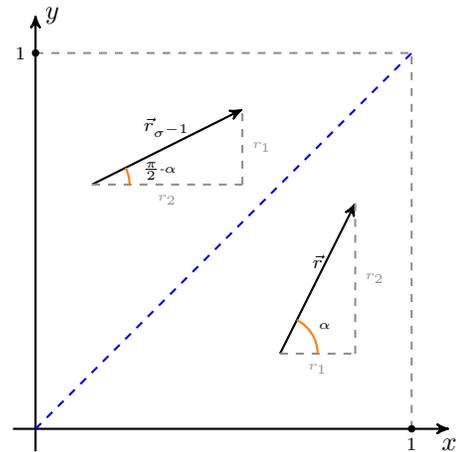
*Teorema 3.4:* (Teorema 6.5 de [16]) Sean  $\vec{0} \neq \vec{r}, \vec{s} \in \mathbb{R}^n$  y  $a, b \in \mathbb{R}^+$ . Supongamos que  $x = (x_1, \dots, x_n) \in [0, 1]^n$ ,  $c > 0$  y  $\sigma$  es una permutación que ordena los elementos de  $x$ . Si  $x_{\sigma(1)} \geq \dots \geq x_{\sigma(n)}$  y  $x_{\sigma} + c(a\vec{r} + b\vec{s}) \in [0, 1]^n$ , entonces o  $x_{\sigma} + ca\vec{r} \in [0, 1]^n$  o  $x_{\sigma} + cb\vec{s} \in [0, 1]^n$ . Por lo tanto, si una función es  $\vec{r}$ - y  $\vec{s}$ -creciente SOD, entonces es  $(a\vec{r} + b\vec{s})$ -creciente SOD.

Nótese que lo mismo puede probarse para funciones OD crecientes [11]. Estudiemos ahora el caso particular de los elementos de la diagonal. Recordemos, que como se ha mencionado anteriormente en la Nota 1, los elementos  $\bar{x} = (x, x) \in \Delta$  satisfacen que  $\bar{x} \in \Omega_1$  y  $\bar{x} \in \Omega_2$ , simultáneamente. Esto significa que los elementos de la diagonal en las funciones  $\vec{r}$ -crecientes SOD crecen en dos direcciones distintas.

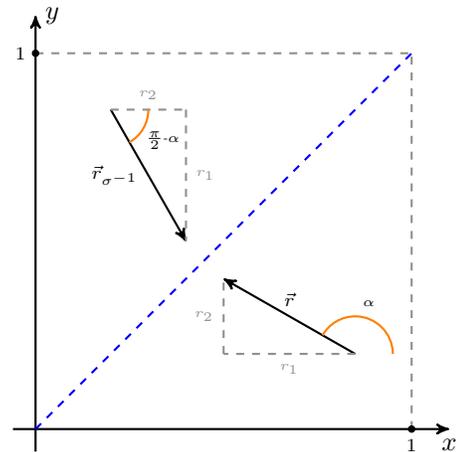
*Corolario 3.5:* Sea  $\vec{0} \neq \vec{r} = (r_1, r_2) \in \mathbb{R}^2$  y sea  $F$  una función  $\vec{r}$ -creciente SOD. Para cada elemento de la diagonal  $\bar{x} \in \Delta$ , se tiene que  $F$  es  $(r_1, r_2)$ - y  $(r_2, r_1)$ -creciente SOD en  $\bar{x}$ .

Sea  $F$  una función  $\vec{r} = (r_1, r_2)$ -creciente SOD para un vector  $\vec{r}$  satisfaciendo  $r_1 \neq -r_2$ . Por el Corolario 3.5, se tiene que  $F$  es una función  $(r_1, r_2)$ - y  $(r_2, r_1)$ -creciente en  $\bar{x}$ , para todo elemento  $\bar{x} \in \Delta$ . Entonces, debido al Teorema 3.4,  $F$  es creciente en  $\bar{x}$  a través de cualquier dirección entre  $(r_1, r_2)$  y  $(r_2, r_1)$  (véase Fig. 4(a)).

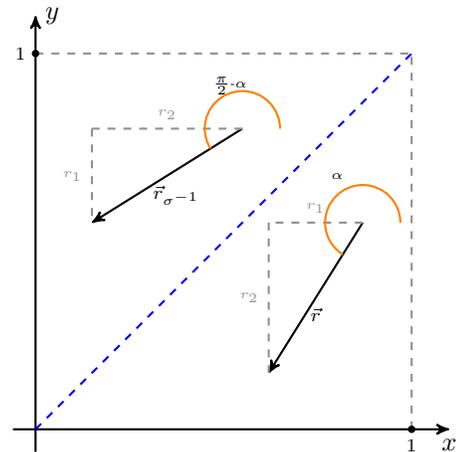
Dos casos extremos de direcciones son los vectores  $\vec{r} = (-r, r)$  cuyo ángulo es  $\alpha = \frac{3\pi}{4}$  y  $\vec{r} = (r, -r)$  cuyo ángulo es  $\alpha = \frac{7\pi}{8}$  (o  $-\frac{\pi}{4}$ ).



a) Vector  $\vec{r}$  con  $r_1 > 0$  y  $r_2 > 0$ .



b) Vector  $\vec{r}$  con  $r_1 < 0$  y  $r_2 > 0$ .



c) Vector  $\vec{r}$  con  $r_1 < 0$  y  $r_2 < 0$ .

Fig. 3. Ejemplos de algunas direcciones  $(r_1, r_2)$  para funciones crecientes OD y SOD: caso a)  $r_1 > 0$  y  $r_2 > 0$ ; b)  $r_1 > 0$  y  $r_2 < 0$  y c)  $r_1 < 0$  y  $r_2 < 0$ .



**Proposición 3.6:** Sea  $r > 0$  y  $F$  una función  $(r, -r)$ -creciente SOD. Para todo  $(x_1, x_2) \in [0, 1]^2$ , se cumple que  $F(x_m, x_m) \leq F(x_1, x_2)$ , donde  $x_m = \frac{x_1 + x_2}{2}$ .

**Demostración:** Sea  $F$  una función  $(r, -r)$ -creciente SOD,  $(x_1, x_2) \in [0, 1]^2$  y  $x_m = \frac{x_1 + x_2}{2}$ . Como consecuencia del Corolario 3.5,  $F$  es  $(r, -r)$  y  $(-r, r)$ -creciente en  $\bar{x}_m = (x_m, x_m) \in \Delta$ . Distinguimos dos posibles casos dependiendo del punto  $x = (x_1, x_2)$ .

- Caso 1: Sea  $(x_1, x_2) \in \Omega_1$ . Dado  $c = \frac{x_1 - x_2}{2r} \geq 0$ , se cumple que  $(x_m, x_m) + c(r, -r) = (x_1, x_2)$  y, por lo tanto,  $F(x_m, x_m) \leq F(x_1, x_2)$ .
- Caso 2: Sea  $(x_1, x_2) \in \Omega_2$ . Dado  $c = \frac{x_2 - x_1}{2r} \geq 0$ , se cumple que  $(x_m, x_m) + c(-r, r) = (x_1, x_2)$  y, por lo tanto,  $F(x_m, x_m) \leq F(x_1, x_2)$ .

Como consecuencia de la Proposición anterior se puede concluir que si una función es  $(r, -r)$ -increasing SOD, para algún  $r > 0$ , se cumple que  $F(\bar{x}) \leq F(y_1, y_2)$  para todo punto satisfaciendo  $y_1 + y_2 = 2x$ , es decir, el valor en el punto de la diagonal es mínimo con respecto a todos los demás puntos de la recta que pasa por el punto con dirección  $(-r, r)$  (véanse líneas verdes en la Fig. 4(b)).

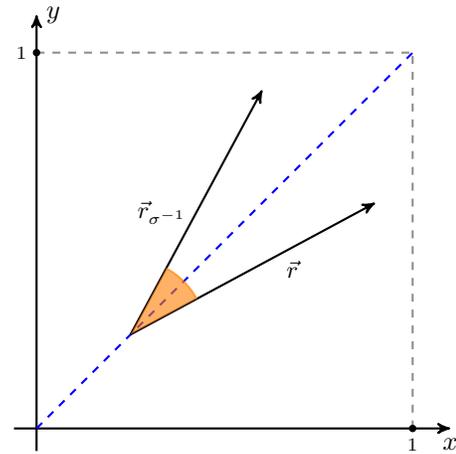
**Proposición 3.7:** Sea  $r > 0$  y  $F$  una función  $(-r, r)$ -creciente SOD. Para todo  $(x_1, x_2) \in [0, 1]^2$ , se cumple que  $F(x_m, x_m) = F(x_1, x_2)$ , donde  $x_m = \frac{x_1 + x_2}{2}$ .

**Demostración:** Sea  $F$  una función  $(-r, r)$ -creciente SOD,  $(x_1, x_2) \in [0, 1]^2$  y  $x_m = \frac{x_1 + x_2}{2}$ . Como consecuencia del Corolario 3.5,  $F$  es  $(-r, r)$  y  $(r, -r)$ -creciente en  $\bar{x}_m = (x_m, x_m) \in \Delta$ . Distinguimos dos posibles casos dependiendo del punto  $x = (x_1, x_2)$ .

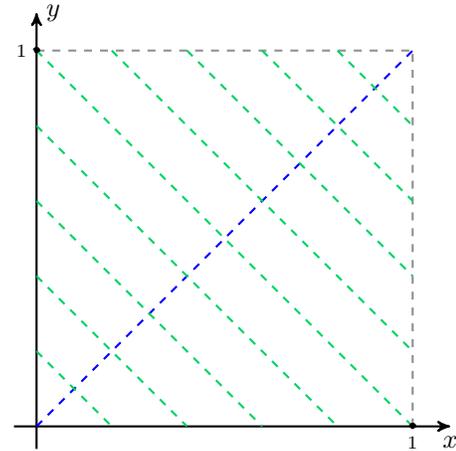
- Caso 1: Sea  $(x_1, x_2) \in \Omega_1$ . Dado  $c = \frac{x_1 - x_2}{2r} \geq 0$ , se cumple  $(x_1, x_2) + c(-r, r) = (x_m, x_m)$ . Como  $F$  es  $(-r, r)$ -creciente en  $(x_1, x_2)$ , se tiene que  $F(x_1, x_2) \leq F(x_m, x_m)$ . De manera similar, se tiene que  $(x_m, x_m) + c(r, -r) = (x_1, x_2)$ . Como  $F$  es también  $(r, -r)$ -creciente en  $(x_m, x_m)$ , se cumple que  $F(x_m, x_m) \leq F(x_1, x_2)$ . Por lo tanto,  $F(x_1, x_2) = F(x_m, x_m)$ .
- Caso 2: Sea  $(x_1, x_2) \in \Omega_2$ . Dado  $c = \frac{x_2 - x_1}{2r} \geq 0$ , se cumple que  $(x_1, x_2) + c(r, -r) = (x_m, x_m)$ . Como  $F$  es  $(r, -r)$ -creciente en  $(x_1, x_2)$  (nótese que en  $\Omega_2$ ,  $\sigma_2(1) = 2$  y  $\sigma_2(2) = 1$ ), y se tiene que  $F(x_1, x_2) \leq F(x_m, x_m)$ . De manera similar, se tiene que  $(x_m, x_m) + c(-r, r) = (x_1, x_2)$ . Como  $F$  es también  $(-r, r)$ -creciente en  $(x_m, x_m)$ , se cumple que  $F(x_m, x_m) \leq F(x_1, x_2)$ . Por lo tanto,  $F(x_1, x_2) = F(x_m, x_m)$ .

#### IV. CONCLUSIONES

En la literatura reciente encontramos diversas nociones de monotonía menos restrictivas que la monotonía en cada variable que se impone a la funciones de agregación. En este trabajo, hemos analizado la interpretación geométrica de estas monotonías. Se ha estudiado la diferencia entre monotonía direccional ordenada y monotonía direccional ordenada reforzada, viendo que la principal diferencia es que



a) Direcciones de crecimiento en los puntos de la diagonal de una función  $\vec{r}$ -creciente SOD.



b) Líneas paralelas con dirección  $(-r, r)$ .

Fig. 4. Representación gráfica del comportamiento de las funciones  $\vec{r} = (r_1, r_2)$ -creciente SOD con  $r_1 = -r_2$ .

la monotonía direccional ordenada restringe sus condiciones de monotonía al subespacio  $\Omega$  en el que se encuentra. El análisis geométrico llevado a cabo para el caso 2-dimensional, también nos ha permitido deducir algunas consecuencias del comportamiento de las funciones direccionalmente ordenadas reforzadas cuando el vector de las direcciones  $\vec{r} = (r_1, r_2)$  satisface que  $r_1 = -r_2$ .

Como trabajo a futuro, destaca la posibilidad de realizar un estudio más general de la interpretación geométrica para el caso  $n$ -dimensional. En este caso, se perdería la posibilidad de dibujar el dominio en el plano, pero existe una mayor cantidad de permutaciones posibles, que darían un mayor número de regiones donde las direcciones varían.

#### REFERENCIAS

- [1] G. Beliakov, S. James, and D. G. Nimmo, "Using aggregation functions to model human judgements of species diversity," *Information Sciences*, vol. 306, pp. 21–33, 2015.
- [2] U. Bentkowska, "Aggregation of diverse types of fuzzy orders for decision making problems," *Information Sciences*, vol. 424, pp. 317–336, 2018.

- [3] D. Paternain, H. Bustince, M. Pagola, P. Sussner, A. Kolesárová, and R. Mesiar, “Capacities and overlap indexes with an application in fuzzy rule-based classification systems,” *Fuzzy Sets and Systems*, vol. 305, pp. 70–94, 2016.
- [4] J. L. García-Lapresta and R. A. M. Pereira, “The dual decomposition of aggregation functions and its application in welfare economics,” *Fuzzy Sets and Systems*, vol. 281, pp. 188–197, 2015.
- [5] M. Grabisch, J.-L. Marichal, R. Mesiar, and E. Pap, “Aggregation functions: Construction methods, conjunctive, disjunctive and mixed classes,” *Information Sciences*, vol. 181, no. 1, pp. 23–43, 2011.
- [6] E. P. Klement, R. Mesiar, and E. Pap, *Triangular Norms*. Springer, Dordrecht, 2000.
- [7] J. Fodor and B. D. Baets, *Studies in Fuzziness and Soft Computing, vol 215*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, ch. Uninorm Basics, pp. 49–64.
- [8] H. Bustince, J. Fernandez, R. Mesiar, J. Montero, and R. Orduna, “Overlap functions,” *Nonlinear Analysis: Theory, Methods & Applications*, vol. 72, no. 3-4, pp. 1488–1499, 2010.
- [9] T. Wilkin and G. Beliakov, “Weakly monotonic averaging functions,” *International Journal of Intelligent Systems*, vol. 30, no. 2, pp. 144–169, 2015.
- [10] H. Bustince, J. Fernandez, A. Kolesárová, and R. Mesiar, “Directional monotonicity of fusion functions,” *European Journal of Operational Research*, vol. 244, no. 1, pp. 300–308, 2015.
- [11] H. Bustince, E. Barrenechea, M. Sesma-Sara, J. Lafuente, G. Dimuro, R. Mesiar, and A. Kolesárová, “Ordered directionally monotone functions. Justification and application,” *IEEE Transactions on Fuzzy Systems (In Press)*.
- [12] G. Lucca, J. A. Sanz, G. P. Dimuro, B. Bedregal, R. Mesiar, A. Kolesárová, and H. Bustince, “Preaggregation functions: Construction and an application,” *IEEE Transactions on Fuzzy Systems*, vol. 24, no. 2, pp. 260–272, 2016.
- [13] G. Lucca, J. A. Sanz, G. P. Dimuro, B. Bedregal, H. Bustince, and R. Mesiar, “CF-integrals: a new family of pre-aggregation functions with application to fuzzy rule-based classification systems,” *Information Sciences*, vol. 435, pp. 94–110, 2017.
- [14] M. Sesma-Sara, H. Bustince, E. Barrenechea, J. Lafuente, A. Kolesárová, and R. Mesiar, “Edge detection based on ordered directionally monotone functions,” in *Advances in Fuzzy Logic and Technology 2017*. Springer, 2017, pp. 301–307.
- [15] C. Marco-Detchart, C. Lopez-Molina, J. Fernandez, M. Pagola, and H. Bustince, *Information Processing and Management of Uncertainty in Knowledge-Based Systems. Theory and Foundations. IPMU 2018*. Springer, 2018, ch. Image Feature Extraction Using OD-Monotone Functions.
- [16] M. Sesma-Sara, J. Lafuente, A. F. Roldán-López-de-Hierro, R. Mesiar, and H. Bustince, “Strengthened ordered directionally monotone functions. Links between the different notions of monotonicity,” *Submitted to Fuzzy Sets and Systems*.
- [17] M. Grabisch, J. Marichal, R. Mesiar, and E. Pap, *Aggregation functions*. Cambridge University Press, 2009.
- [18] G. Beliakov, H. Bustince, and T. Calvo, *A Practical Guide to Averaging Functions*, ser. Studies in Fuzziness and Soft Computing. Springer International Publishing, 2016.



# Operadores de agregación y comparación para diferenciación de señales discretas

C. Lopez-Molina, S. Iglesias-Rey, H. Bustince  
Dpto. Estadística, Informática y Matemáticas  
Universidad Pública de Navarra  
Pamplona, Spain  
Email: carlos.lopez@unavarra.es

N. Madrid  
Escuela de Ingenierías Industriales  
Universidad de Málaga  
Málaga, España  
Email: nicolas.madrid@uma.es

**Abstract**—La tecnología digital ha hecho que la mayor parte de los datos se registren en forma de señales discretas. A pesar de las ventajas que esto tiene, la naturaleza de esta información representa desafíos novedosos. En este trabajo analizamos la diferenciación de señales discretas, una tarea básica para el procesamiento automático de las mismas. En concreto, proponemos el uso de operadores de comparación y agregación para la generación de familias de operadores de diferenciación con alta interpretabilidad. Nuestra propuesta es validada en el contexto de procesamiento de imagen, con la finalidad de caracterizar derivadas parciales en señales bidimensionales.

**Index Terms**—Operadores de agregación; operadores de comparación; diferenciación de señales discretas; filtros de convolución.

## I. INTRODUCCIÓN

La era digital ha producido un incremento exponencial en la cantidad de datos recogidos en casi cualquier ámbito de conocimiento. Esto ha provocado cambios en la manera de tratar información, siendo uno de los más importantes el papel del procesamiento de señal [1], [2]. Nótese que el procesamiento de señal trata con datos nativamente representados en forma de señal (audio, imagen, video), y también de datos escalares recogidos en forma de señal (como las series temporales o los espacios-escala). El procesamiento de señal, entendido de una manera amplia, es una rama aplicada del análisis matemático. Sin embargo, la portabilidad de algoritmos entre ambos campos está en ocasiones muy dificultada por la naturaleza discreta de las señales digitales.

En este trabajo nos centramos en el problema de la diferenciación de señales discretas [3]. La importancia de la diferenciación (e integración) en el procesamiento de señal es capital [4]. Ambas operaciones, aunque en especial la primera de ellas, se usan para localizar tanto puntos críticos (p.e. máximos o mínimos locales) como para localizar o *clusterizar* regiones de interés en las señales. Un ejemplo de fácil interpretación es el de las imágenes en escala de grises. En estas imágenes, entendidas como señales discretas bidimensionales, el uso de derivadas parciales es central a casi cualquier procesamiento de medio o alto nivel. Las diferencias parciales permiten analizar la variación local de las imágenes, y suponen la información primaria en aplicaciones que incluyen la segmentación, detección de bordes, la búsqueda de puntos de interés y la regularización adaptativa.

Muchas de las propuestas para diferenciación de señales discretas están basadas en filtros de convolución para primera o segunda derivada. Al inicio de la era digital aparecieron filtros de convolución discretos, generalmente asociados al cómputo de gradientes en imágenes digitales [5], [6], [7]. En los años 80, nuevos trabajos se inspiraron en el análisis matemático para diseñar filtros continuos, que debían ser discretizados para su aplicación. Esta naturaleza continua les permitía, antes de la discretización, presentarse como óptimos ante ciertos criterios de calidad [8], [9]. Estos trabajos incluyen las propuestas de Marr y Hildreth [10] y Canny [11], [12], así como ciertas expansiones posteriores [9], [13].

El estudio de filtros de convolución para el cálculo de diferencias parciales se ha visto frenado en los últimos 20 años. A pesar de que se han presentado trabajos de impacto, estos generalmente se limitan a reescribir los criterios de optimalidad y derivar nuevas propuestas, sin que esto repercuta claramente en una mejora en la aplicabilidad [14], [15], [16]. Si bien es cierto que la aparición de los espacios-escala para el análisis multidimensional de señales ha aportado cierta novedad en la diferenciación de señales discretas [17], [18], apenas ha sido aprovechado para producir mejores análisis diferenciales [19].

En este trabajo analizamos los filtros de convolución para el cálculo de diferencias parciales, con especial atención a la diferenciación parcial de imágenes. En concreto, reformulamos el proceso de convolución para considerar, de manera independiente, (a) la cuantificación de diferencias locales y (b) el modelado del vecindario de interés en torno a cada punto de la señal. Esta reformulación viene inspirada por los filtros bilaterales de Tomasi y Manduchi [20], así como por otras iniciativas de aplicación de operadores de agregación en la caracterización de diferencias parciales en imágenes [21]. Proponemos esta generalización para poder incorporar a este campo diferentes operadores de la Teoría de Conjuntos Difusos, en particular las funciones de disimilitud restringidas y las funciones de agregación.

En la Sección II repasamos algunos conocimientos básicos de aplicación en este trabajo. Las Secciones III y III desgranar la propuesta, que es validada de manera experimental en la Sección V. Para finalizar, la Sección VI lista algunas conclusiones y futuras líneas de trabajo.

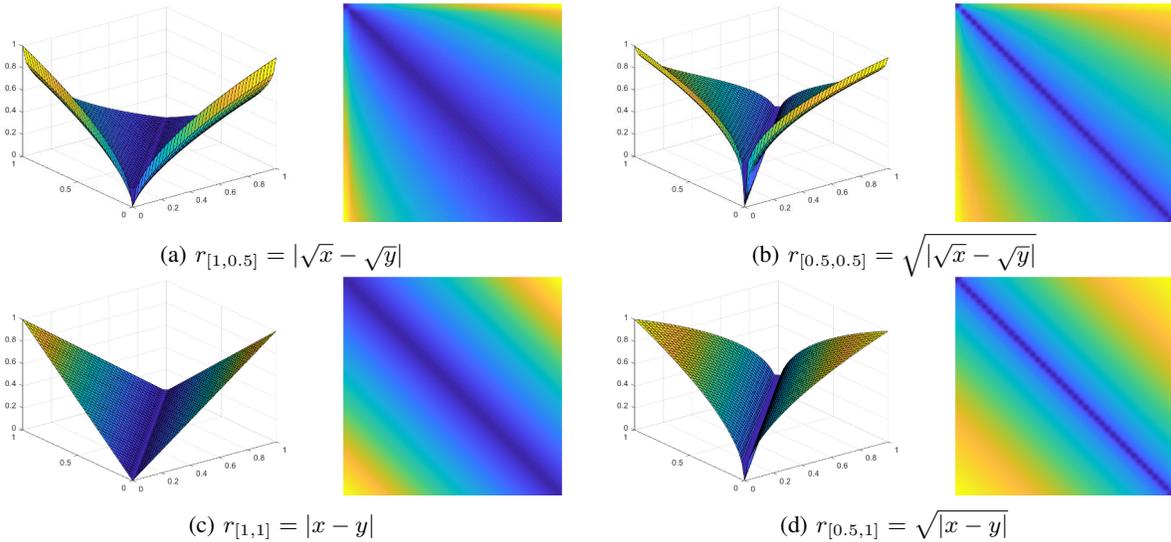


Fig. 1. Funciones de disimilitud restringidas construidas de acuerdo a la Proposición 1.

## II. PRELIMINARIES

La teoría de funciones de comparación ha tenido un impacto significativo en la Teoría de Conjuntos Difusos. Esto se debe, probablemente, a la naturaleza subjetiva de las comparaciones humanas, en la cuales pueden aparecer ambigüedades e inconsistencias. En este contexto, la Teoría de Conjuntos Difusos ha sido prolífica, bien fuera centrada en términos de métricas [22] o en términos de medidas de similitud [23]. En este trabajo usamos las Funciones de Disimilitud Restringidas (o, RDFs, por sus siglas inglesas [24]). Estas funciones modelan la diferencia perceptual entre dos elementos en el intervalo  $[0, 1]$ , y han sido aplicadas en diferentes contextos [25], [26].

*Definition 1:* [24] Una *función de disimilitud restringida* es una aplicación  $r : [0, 1]^2 \rightarrow [0, 1]$  que satisfaga

- (R1)  $r(x, y) = r(y, x)$  para todo  $x, y \in [0, 1]$ ;
- (R2)  $r(x, y) = 1$  si y sólo si  $x = 0$  e  $y = 1$  o  $x = 1$  e  $y = 0$ ;
- (R3)  $r(x, y) = 0$  si y sólo si  $x = y$ ;
- (R4) para todo  $x, y, z \in [0, 1]$ , si  $x \leq y \leq z$ , entonces  $r(x, y) \leq r(x, z)$  y  $r(y, z) \leq r(x, z)$ .

Existen diferentes maneras de construir RDFs, si bien la más sencilla es la combinación de automorfismos.

*Proposition 1:* Sean  $\varphi_1$  y  $\varphi_2$  dos automorfismos de  $[0, 1]$ . La aplicación  $r : [0, 1]^2 \rightarrow [0, 1]$  construída tal que

$$r(x, y) = \varphi_1(|\varphi_2(x) - \varphi_2(y)|) \quad (1)$$

es una función de disimilitud restringida (o RDF).

De cara a reducir el alcance de este trabajo, consideraremos únicamente las RDFs construídas de acuerdo a la Proposición 1. Específicamente, nos referiremos como  $r_{[\alpha, \beta]}$ , con  $\alpha, \beta \in \mathbb{R}$ , a la RDF tal que  $\varphi_1(x) = x^\alpha$  y  $\varphi_2(x) = x^\beta$ . Es decir, a

$$r_{[\alpha, \beta]}(x, y) = (|x^\beta - y^\beta|)^\alpha. \quad (2)$$

La Fig. 1 muestra algunas RDFs construídas de acuerdo a la Ec. (2). Nótese que  $r_{[1,1]}$  es equivalente a la diferencia absoluta entre los argumentos de la función.

## III. UN MODELO GENERAL PARA DIFERENCIACIÓN

La noción de *derivada* está ligada a la idea de variación de una función. Por ello, al trabajar con funciones sobre dominios discretos, la diferencia local puede tomarse como un reemplazo fidedigno de la derivada. Sean dos funciones  $f : \mathbb{R}^2 \mapsto \mathbb{R}$  y  $g : \mathbb{N}^2 \mapsto \mathbb{R}$  tal que la segunda (mediciones) se construya a partir del muestreo de la primera (realidad subyacente). Podría aproximarse la derivada de  $f$  tal que:

$$\begin{aligned} \frac{\partial f}{\partial x}(i, j) &= g(i+1, j) - f(i, j) \text{ y} \\ \frac{\partial f}{\partial y}(i, j) &= g(i, j+1) - f(i, j). \end{aligned} \quad (3)$$

Sin embargo, la aplicación de esta estrategia suele generar resultados decepcionantes, en buena medida debido a la contaminación de los datos. En entornos reales, el empleo de Ec. (3) es poco fiable, y sus resultados tienen una interpretabilidad muy baja. Un ejemplo de este hecho se ve en la Fig. 2. En esta figura vemos, en la fila superior, dos señales sintéticas, tal que la situada en la columna derecha es una versión contaminada de la que ocupa la columna izquierda. En esta señal coexisten dos *objetos* cada uno de los cuales genera dos puntos de interés (críticos), uno a cada lado del propio objeto. Estos puntos deberían representarse como dos máximos (subidas, al lado izquierdo de cada objeto) y dos mínimos (bajadas, al lado derecho). En la segunda fila de la Fig. 2 vemos la aproximación a  $\frac{\partial f}{\partial x}$  realizada por el filtro de Lalignant [15], que corresponde en su versión 1D a la formulación de la Ec. (3). Se observa que el resultado es muy preciso en la señal sintética original, pero también muy poco interpretable en la señal contaminada. Esto se achaca a la alta frecuencia del muestreo para computar la diferencia (dos posiciones contiguas), lo que generalmente se soluciona usando operadores de mayor soporte.

Al usar un filtro de diferenciación la aproximación a las derivadas parciales de  $f$  se hace mediante la convolución de

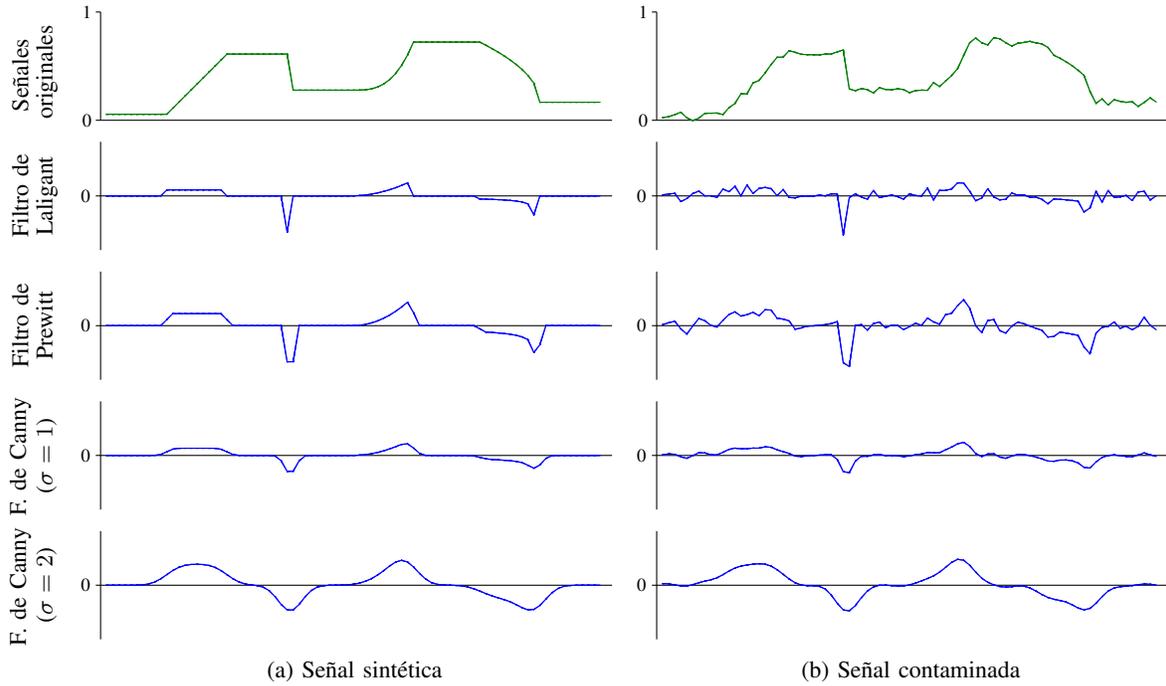


Fig. 2. Estimaciones de la primera derivada de una señal discreta usando diferentes filtros de convolución 1D. La señal contaminada se obtiene añadiendo ruido blanco Gaussiano con desviación estándar 0.02. Los operadores usados son el de Laligant [15], Prewitt [6] and Canny [12], y pueden observarse en la Fig. 3.

la señal  $g$  con un filtro  $\kappa$ . Algunos ejemplos son los operadores discretos de Sobel [5] y Prewitt [6], o los operadores basados en señales continuas de Canny [11] (y sus evoluciones [16], [27]) o Shen-Castan [28]. Algunos de estos filtros, en su representación 1D, se incluyen en la Fig. 3.

Una derivada parcial en  $x$  en el punto  $\mathbf{p}$  se aproxima tal que<sup>1</sup>:

$$\frac{\partial f}{\partial x}(\mathbf{p}) = g * \kappa(\mathbf{p}) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \kappa(\xi) \cdot f(\mathbf{p} + \xi) \cdot d\xi, \quad (4)$$

donde  $\xi$  representa el desplazamiento.

La elección de  $\kappa$ , así como los parámetros que éste pudiera tener, ha sido ampliamente discutido en la comunidad científica. En esta discusión toman relevancia las características de las funciones a derivar, las contaminaciones que pueda sufrir, o la finalidad del proceso. De hecho, muchas propuestas son óptimas para el conjunto de restricciones y objetivos propuestos por sus autores, si bien estos difieren unos de otros. Una de las propiedades más aceptada es la antisimetría o imparidad, es decir, que para cualquier  $\xi$  en el dominio se cumple que  $\kappa(\xi) = -\kappa(-\xi)$ . Esta propiedad no siempre se cumple en los filtros de diferenciación, véase el caso del filtro de Laligant [15] en la Fig. 3, pero sí es sostenida en la mayor parte de los casos. Nótese que, en algunos filtros (como el ISEF [28], ver Fig. 3) el filtro no está definido en el origen, suponiéndose un valor 0.

<sup>1</sup>En adelante, se considera únicamente la derivada  $\frac{\partial f}{\partial x}$ , ya que la derivada  $\frac{\partial f}{\partial y}$  se computa de manera análoga.

Partiendo de la Ec. (4), y dando por hecha la antisimetría del filtro  $\kappa$ , tenemos que:

$$\begin{aligned} g * \kappa(\mathbf{p}) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \kappa(\xi) \cdot g(\mathbf{p} + \xi) \cdot d\xi = \\ &= \int_{-\infty}^{\infty} \int_0^{\infty} \kappa(\xi) g(\mathbf{p} + \xi) d\xi + \int_{-\infty}^{\infty} \int_{-\infty}^0 \kappa(\xi) g(\mathbf{p} + \xi) d\xi = \\ &= \int_{-\infty}^{\infty} \int_0^{\infty} \kappa(\xi) g(\mathbf{p} + \xi) d\xi + \int_{-\infty}^{\infty} \int_0^{\infty} \kappa(-\xi) g(\mathbf{p} - \xi) d\xi = \\ &= \int_{-\infty}^{\infty} \int_0^{\infty} \kappa(\xi) g(\mathbf{p} + \xi) d\xi - \int_{-\infty}^{\infty} \int_0^{\infty} \kappa(\xi) g(\mathbf{p} - \xi) d\xi = \\ &= \int_{-\infty}^{\infty} \int_0^{\infty} \kappa(\xi) (g(\mathbf{p} + \xi) - g(\mathbf{p} - \xi)) d\xi. \end{aligned} \quad (5)$$

Los dominios de las señales se definen, en el plano teórico, con dominio infinito. Por ejemplo, un filtro Gaussiano es, evidentemente, positivo en  $[-\infty, \infty]$ , que pasa a ser el rango de las integrales en Ec. (5). Sin embargo, en las aplicaciones prácticas esto no tiene demasiada relevancia, y los filtros se restringen a un cierto soporte discreto a partir del cual se considera que  $K(\xi) = 0$ . Por tanto, se puede reformular el resultado de la Ec. (5) tal que:

$$g * \kappa(i) = \int_{-t}^t \int_0^t \kappa(\xi) \cdot (g(\mathbf{p} + \xi) - g(\mathbf{p} - \xi)) \cdot d\xi. \quad (6)$$

donde  $[-t, t]^2$  es el soporte del filtro  $\kappa$ , generalmente establecido a partir del descenso del valor  $\kappa$  por debajo de un cierto umbral cercano a 0.

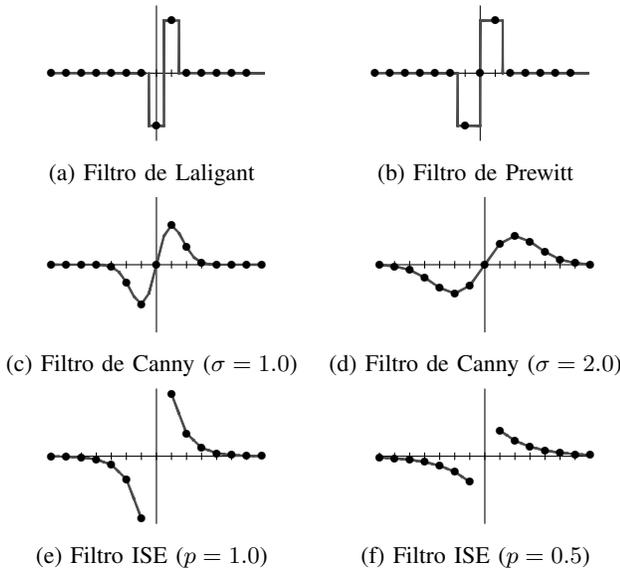


Fig. 3. Filtros de convolución 1D usados para diferenciación. Los puntos representan la versión discreta, mientras que la línea señala la función continua subyacente.

La estimación de las derivadas parciales de una señal  $g$  involucra, pues, dos componentes diferentes:

- la cuantificación de las diferencias entre los valores a ambos lados de la posición, representado en la Ec. (6) por el término  $(g(x + \xi) - g(x - \xi))$ . Nos referimos a este término como *término de intensidad*;
- la cuantificación de la relevancia de cada posición en el entorno, representado en la Ec. (6) por el término  $\kappa(\xi)$ . Nos referimos a este término como *término espacial*.

Al tener ambos términos identificados, podemos modelarlos de manera independiente. Por ejemplo, en lugar de considerar la diferencia absoluta entre los valores de la señal  $g$ , podemos modelar el término de intensidad usando otras medidas. Dado que las señales discretas suelen tener límites bien definidos, podemos considerar que  $f$  y  $g$  tienen el rango  $[0, 1]$ . Para el *término de intensidad* de la Ec. (6) consideramos una función de diferencia tal que  $\epsilon: [0, 1]^2 \rightarrow [-1, 1]$ . Esta función debe encargarse de cuantificar la diferencia percibida entre dos valores, sean  $g(\mathbf{p} - \xi)$  y  $g(\mathbf{p} + \xi)$ . La Ec. (6) resulta en:

$$g * \kappa(\mathbf{p}) = \int_{-k}^k \int_0^k \kappa(\xi) \cdot \epsilon((g(\mathbf{p} + \xi), g(\mathbf{p} - \xi))) \cdot d\xi \quad (7)$$

Así, las derivadas parciales dependen de dos piezas de información: el filtro que modela la relevancia espacial ( $\kappa$ ) y la función que modula la disimilitud ( $\epsilon$ ). Cada uno de estos debería poder estudiarse y entrenarse de manera independiente. Además, ambos se combinan de manera local usando un operador conjuntivo (producto) y de manera semi-local usando la suma (media aritmética, en caso de normalización).

En este trabajo nos centramos en el término de intensidad, relacionándolo con la teoría de comparación. En concreto, estudiamos el papel que pueden tener las funciones de disimilitud restringidas para el modelado de las diferencias.

#### IV. DIFERENCIACIÓN USANDO FUNCIONES DE DISIMILITUD RESTRINGIDAS

Dada la Ec. (7), una pregunta evidente se refiere al conjunto mínimo de propiedades que debe cumplir la función  $\epsilon$ . Por ejemplo, debería producir valores *altos* cuando sus argumentos sean diferentes, mientras que deberían ser bajos o cercanos a cero cuando los argumentos sean similares. Sería esperable también la antisimetría, ya que las derivadas de una función no deberían verse afectadas por la dirección del análisis (más allá del signo de las mismas). Creemos que una función  $\epsilon$  debe cumplir las siguientes propiedades:

- (E1)  $\epsilon_r(y, z) = -\epsilon_r(z, y)$ ;
- (E2)  $\epsilon_r(y, z) = 0$  si y sólo si  $y = z$ ;
- (E3a)  $\epsilon_r(y, z) = 1$  si y sólo si  $y = 0$  y  $z = 1$ ;
- (E3b)  $\epsilon_r(y, z) = -1$  si y sólo si  $y = 1$  y  $z = 0$ ;
- (E4) Para cada  $t, y, z \in [0, 1]$ ,  $t \leq y \leq z$ , tenemos que  $\epsilon_r(t, y) \leq \epsilon_r(t, z)$  y  $\epsilon_r(y, z) \leq \epsilon_r(z, t)$ .

Estas propiedades garantizan el comportamiento esperado en el término de intensidad. Por ejemplo, (E2) garantiza que la derivada de una función será 0 si y sólo si  $g(k + \xi) = g(k - \xi)$  para cada posición  $\xi \in [-t, t]^2$ .

Tras un análisis detallado, creemos que las RDF suponen una herramienta útil para generar funciones  $\epsilon$ . En concreto, proponemos usar funciones  $\epsilon$  construidas tal que:

$$\epsilon_r(y, z) = \frac{z - y}{|z - y|} \cdot r(y, z), \quad (8)$$

donde  $r$  es una RDF. Una función  $\epsilon_r$ , construida como en la Ec. (8), satisface las propiedades (E1)-(E4).

Trabajos anteriores han estudiado las técnicas clásicas de filtrado para incorporar dos términos independientes (y explícitos), especialmente en el campo de procesamiento de imagen. Las técnicas de regularización o diferenciación adaptadas al contenido local de la imagen (*content-aware filtering*), por ejemplo, discriminan el análisis de tonos (el término de intensidad) con el estudio de la posición de cada pixel (el término espacial). La manera en que los términos se aplican y combinan puede, sin embargo, ser diferente. La contribución más relevante en este sentido, así como la más parecida a nuestro objetivo, es el *filtrado bilateral* de Tomasi y Manduchi (*bilateral filtering* [20]). En este trabajo, los autores proponen la combinación de filtros en las dimensiones tonal y espacial para la regularización adaptativa de imágenes. Estos filtros consideran la cercanía tonal y espacial de cada par de píxeles a la hora de regularizar una zona de la imagen. Específicamente, proponen generar una imagen regularizada  $g^*$  a partir de una imagen monocanal  $g$  tal que:

$$g^*(\mathbf{p}) = \frac{1}{k_d} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} s(\xi) \cdot g(\mathbf{p} + \xi) \cdot h(|g(\mathbf{p}) - g(\mathbf{p} + \xi)|) d\xi \quad (9)$$

donde  $k_d$  es un factor de normalización,  $s$  es un filtro de paso bajo y  $h$  es una función unaria decreciente. En esta formulación,  $s$  modula el peso de los elementos en función de su distancia a  $\mathbf{p}$ , mientras que  $h$  modula el peso de los elementos en función de su diferencia de valor respecto a  $g(\mathbf{p})$ .



Los filtros bilaterales se han aplicado en diferentes escenarios, si bien se han mantenido casi siempre en el ámbito de la regularización adaptativa. Los objetivos, sin embargo, han variado, desde la regularización sin contexto (en el trabajo original [20]) a la eliminación de ruido o texturas [29]. Algunos autores han relacionado los filtros bilaterales con otras estrategias de regularización adaptativas y análisis de datos, como pueden ser la difusión anisotrópica o el *mean-shift* [30], [31], [32]. Finalmente, en 2017, Wilkin y Beliaikov presentaron una reformulación de los filtros bilaterales [21] usando funciones débilmente monótonas (*weakly monotone functions* [33]).

Nuestra propuesta, aunque es conceptualmente similar a la de Tomasi y Manduchi, tiene una formulación diferente. El cambio más significativo es que el término de intensidad incluye dos posiciones simétricas respecto a  $\mathbf{p}$ , mientras que en un filtro bilateral se evalúa la similitud tonal entre los valores respecto de la posición central (ver Ec. (9)). Otra diferencia significativa es que el dominio espacial de los filtros bilaterales es simétrico desde el origen ( $\mathbf{p}$ ), mientras que en la Ec. (7)  $\kappa$  sólo necesita definirse en la mitad del mismo.

## V. VALIDACIÓN EXPERIMENTAL

La propuesta de la Sección IV se basa en la asunción de que la diferencia aritmética no es necesariamente el mejor descriptor de la disimilitud entre dos valores. O, al menos, de que es bueno tener la capacidad de modelar esta disimilitud por medio de una función dedicada. Esta sección trata de comprobar si el aislar el *término de intensidad* puede conllevar mejoras en los resultados prácticos de una aplicación de diferenciación. Para ello, hemos aplicado nuestras ideas al contexto de detección de bordes.

Proponemos un esquema de detección de bordes relativamente estándar, compuesto por cuatro pasos acordes a la estructura de descomposición de Bezdek [34], [35]:

1. Regularizar la imagen con un filtro Gaussiano con  $\sigma = 1$ ;
2. Calcular los gradientes como la combinación de las derivadas parciales, aproximados de acuerdo a la Ec. (7) con los ajustes que se detallan a continuación.
3. Estimar la intensidad de borde como la magnitud del gradiente en cada píxel.
4. Binarizar la imagen usando *non-maxima suppression* [36] e *hysteresis* [11], para la cuál los umbrales se establecen usando la técnica de Medina-Carnicer *et al.* [37].

Este esquema es una aplicación directa de la diferenciación de señales discretas (imágenes). Los ajustes de nuestros filtros son los que siguen:

- $\epsilon$  se construye como se ve en la Ec. (8), donde las RDFs son del tipo  $r_{[\alpha,\beta]}$  con valores  $\alpha, \beta \in \{0.5, 1, 1.5, \dots, 3\}$ ;
- $\kappa_h$  y  $\kappa_v$  son equivalentes al lado positivo de un filtro de Canny, i.e

$$\kappa_h(\xi) = \frac{-\xi_x}{\sigma^2} e^{-\frac{\xi_x^2 + \xi_y^2}{2\sigma^2}} \quad \text{and} \quad \kappa_v(\xi) = \frac{-\xi_y}{\sigma^2} e^{-\frac{\xi_x^2 + \xi_y^2}{2\sigma^2}}, \quad (10)$$

con  $\sigma = 1$ .

		$\beta$					
		0.5	1.0	1.5	2.0	2.5	3.0
$\alpha$	0.5	.56	.63	.65	.64	.63	.61
	1.0	.56	.63	.64	.63	.61	.58
	1.5	.56	.61	.61	.59	.57	.55
	2.0	.56	.59	.58	.55	.53	.50
	2.5	.55	.57	.55	.52	.49	.47
	3.0	.54	.54	.51	.48	.46	.43

(a) Rendimiento medio (medida  $F$ ) para cada RDF  $r_{[\alpha,\beta]}$ .

		$\beta$					
		0.5	1.0	1.5	2.0	2.5	3.0
$\alpha$	0.5	4/13	26/-	24/-	16/-	16/-	16/3
	1.0	2/3	11/-	14/-	6/-	8/-	2/2
	1.5	4/3	7/1	2/-	1/1	1/1	3/-
	2.0	5/3	3/-	3/-	1/-	-/-	1/2
	2.5	2/9	4/-	2/2	-/-	2/2	6/12
	3.0	2/19	1/5	3/2	1/9	-/13	1/95

(b) Número de imágenes para las cuales cada RDF  $r_{[\alpha,\beta]}$  obtiene el mejor/peor resultados de entre los contendientes.

TABLE I

RESULTADOS CUANTITATIVOS OBTENIDOS EN EL EXPERIMENTO PARA CADA RDF  $r_{[\alpha,\beta]}$  EN EL BSDS500 *test set*.

Nótese que, cuando usamos  $r_{[1,1]}$ , el algoritmo es computacionalmente equivalente al método de Canny. De esta manera, al incluir  $(\alpha, \beta) = (1, 1)$  en la comparación, podemos contrastar la importancia de tener un término independiente y adaptable para la cuantificación de las disimilitudes.

En este experimento utilizamos un esquema estándar de cuantificación de resultados basado en la medida  $F$  [38], [39] sobre el *dataset de test* del BSDS [40].

En la Tabla I mostramos los resultados obtenidos en los experimentos. Primero, en la Tabla I(a) listamos el rendimiento medio de cada combinación de  $(\alpha, \beta)$ . Luego, en la Tabla I(b) mostramos el número de imágenes para los cuales cada combinación de  $(\alpha, \beta)$  produce el mejor y/o peor resultado (en términos de la medida  $F$ ).

Los resultados indican que la combinación  $(\alpha, \beta) = (1, 1)$  (que recupera el método de Canny) no es necesariamente la mejor opción para el término de intensidad. Otras configuraciones producen resultados que son, al menos, competitivos, especialmente con valores bajos de  $\alpha$  y  $\beta$ . Esta conclusión se refiere a los valores medios de rendimiento, pero también a los números de mejores y peores resultados. Son llamativos los casos de  $r_{[0.5,1.0]}$  y, por ejemplo,  $r_{[0.5,2.5]}$ , ya que ambos tienen mejores resultados medios, así como mejores ratios de mejor/peor resultado que  $r_{[1,1]}$ . Si bien experimentos exhaustivos podrían llevarse a cabo para confirmar nuestras hipótesis, creemos que nuestros resultados, dado el limitado espacio, refuerzan nuestra tesis de que la diferencia absoluta podría no ser siempre la mejor medida de disimilitud entre (en este caso) tonos en una imagen y (de manera general) valores en una función discreta.

## VI. CONCLUSIONES

En este trabajo hemos presentado un modelo para generalizar filtros antisimétricos (impares) para la aproximación de derivadas mediante diferencias discretas. Nuestro modelo propone el uso de términos explícitos para las diferencias de valor (término de intensidad) y posición (término espacial). En el caso de las primeras, hemos presentado una clase de funciones de comparación basadas en RDFs que garantizan una serie de propiedades, añadidas a la alta flexibilidad. La validez del modelo se ha testeado en la diferenciación de imágenes en escala de grises para detección de bordes, encontrando que los resultados de algoritmos clásicos pueden mejorarse al usar las RDFs dentro de nuestra reformulación del modelo. Los resultados son prometedores, aunque deberían ser respaldados por trabajos más exhaustivos. Además, cabe señalar que nuestro modelo propuesto abre la puerta al uso de técnicas como el entrenamiento de funciones en el espacio de intensidades (tonos, en el caso de procesamiento de imagen), que en una formulación clásica del problema no eran elegibles.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia del Gobierno de España (Proyectos TIN2016-77356-P y TIN15-70266-C2-P-1).

## REFERENCES

- [1] J. Astola, E. Dougherty, I. Shmulevich, and I. Tabus, "Genomic signal processing," *Signal Processing*, vol. 83, no. 4, pp. 691–694, 2003.
- [2] T.-S. Chua, X. He, W. Liu, M. Piccardi, Y. Wen, and D. Tao, "Big data meets multimedia analytics," *Signal Processing*, vol. 124, pp. 1–4, 2016.
- [3] L. Florack, *Image structure*. Springer Science & Business Media, 1997, vol. 10.
- [4] D. Marr, *Vision*. MIT Press, 1982.
- [5] I. Sobel and G. Feldman, "A 3x3 isotropic gradient operator for image processing," 1968, presented at a talk at the Stanford Artificial Intelligence Project.
- [6] J. M. S. Prewitt, *Object enhancement and extraction*, ser. Picture Processing and Psychopictorics. Academic Press, 1970, pp. 75–149.
- [7] L. G. Roberts, "Machine perception of three-dimensional solids," Ph.D. dissertation, Massachusetts Institute of Technology, 1963.
- [8] R. M. Haralick, "Digital step edges from zero crossing of second directional derivatives," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 6, no. 1, pp. 58–68, 1984.
- [9] M. Basu, "Gaussian-based edge-detection methods- A survey," *IEEE Trans. on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, vol. 32, no. 3, pp. 252–260, 2002.
- [10] D. Marr and E. Hildreth, "Theory of edge detection," *Proceedings of the Royal Society of London*, vol. 207, no. 1167, pp. 187–217, 1980.
- [11] J. Canny, "Finding edges and lines in images," Massachusetts Institute of Technology, Tech. Rep., 1983.
- [12] —, "A computational approach to edge detection," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 8, no. 6, pp. 679–698, 1986.
- [13] G. Wang and B. De Baets, "Edge detection based on the fusion of multiscale anisotropic edge strength measurements," in *Advances in Fuzzy Logic and Technology 2017*. Springer, 2017, pp. 530–536.
- [14] S. Mahmoodi, "Edge detection filter based on Mumford–Shah Green function," *SIAM Journal on Imaging Sciences*, vol. 5, no. 1, pp. 343–365, 2012.
- [15] O. Laligant and F. Truchetet, "A nonlinear derivative scheme applied to edge detection," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 32, no. 2, pp. 242–257, 2010.
- [16] W. McIlhagga, "The Canny edge detector revisited," *International Journal of Computer Vision*, vol. 91, pp. 251–261, 2011.
- [17] T. Lindeberg, "Edge detection and ridge detection with automatic scale selection," *International Journal of Computer Vision*, vol. 30, no. 2, pp. 117–156, 1998.
- [18] J. Weickert, *Anisotropic Diffusion in Image Processing*, ser. ECMI Series. Teubner-Verlag, 1998.
- [19] C. Lopez-Molina, J. Montero, H. Bustince, and B. De Baets, "Self-adapting weighted operators for multiscale gradient fusion," *Information Fusion*, vol. 44, pp. 136–146, 2018.
- [20] C. Tomasi and R. Manduchi, "Bilateral filtering for gray and color images," in *Proc. of the IEEE International Conf. on Computer Vision*, 1998, pp. 838–846.
- [21] T. Wilkin and G. Beliakov, "Robust image denoising and smoothing with generalised spatial-tonal averages," in *IEEE International Conf. on Fuzzy Systems*. IEEE, 2017, pp. 1–7.
- [22] V. Gregori, S. Morillas, and A. Sapena, "Examples of fuzzy metrics and applications," *Fuzzy Sets and Systems*, vol. 170, no. 1, pp. 95–111, 2011.
- [23] S. Santini and R. Jain, "Similarity measures," *IEEE Trans. on Pattern Analysis Machine Intelligence*, vol. 21, no. 9, pp. 871–883, 1999.
- [24] H. Bustince, E. Barrenechea, and M. Pagola, "Relationship between restricted dissimilarity functions, restricted equivalence functions and normal EN-functions: Image thresholding invariant," *Pattern Recognition Letters*, vol. 29, no. 4, pp. 525–536, 2008.
- [25] C. Lopez-Molina, B. De Baets, M. Galar, and H. Bustince, "A generalization of the Perona-Malik anisotropic diffusion method using restricted dissimilarity functions," *International Journal of Computational Intelligent Systems*, vol. 6, no. 1, pp. 14–28, 2013.
- [26] C. Marco-Detchart, J. Cerron, L. De Miguel, C. Lopez-Molina, H. Bustince, and M. Galar, "A framework for radial data comparison and its application to fingerprint analysis," *Applied Soft Computing*, vol. 46, pp. 246–259, 2016.
- [27] P.-L. Shui and W.-C. Zhang, "Noise-robust edge detector combining isotropic and anisotropic Gaussian kernels," *Pattern Recognition*, vol. 45, no. 2, pp. 806–820, 2012.
- [28] J. Shen and S. Castan, "An optimal linear operator for step edge detection," *CVGIP: Graphical Models and Image Processing*, vol. 54, no. 2, pp. 112–133, 1992.
- [29] S. Paris, P. Kornprobst, J. Tumblin, and F. Durand, "Bilateral filtering: Theory and applications," *Foundations and Trends in Computer Graphics and Vision*, vol. 4, no. 1, pp. 1–73, 2008.
- [30] M. Elad, "On the origin of the bilateral filter and ways to improve it," *IEEE Trans. on Image Processing*, vol. 11, no. 10, pp. 1141–1151, 2002.
- [31] D. Barash, "A fundamental relationship between bilateral filtering, adaptive smoothing, and the nonlinear diffusion equation," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 844–847, 2002.
- [32] D. Comaniciu and P. Meer, "Mean shift: a robust approach toward feature space analysis," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, no. 5, pp. 603–619, 2002.
- [33] T. Wilkin and G. Beliakov, "Weakly monotonic averaging functions," *International Journal of Intelligent Systems*, vol. 30, no. 2, pp. 144–169, 2015.
- [34] J. Bezdek, R. Chandrasekhar, and Y. Attikouzel, "A geometric approach to edge detection," *IEEE Trans. on Fuzzy Systems*, vol. 6, no. 1, pp. 52–75, 1998.
- [35] C. Lopez-Molina, "The breakdown structure of edge detection- analysis of individual components and revisit of the overall structure," Ph.D. dissertation, Universidad Publica de Navarra, 2012.
- [36] A. Rosenfeld and M. Thurston, "Edge and curve detection for visual scene analysis," *IEEE Trans. on Computers*, vol. 20, no. 5, pp. 562–569, 1971.
- [37] R. Medina-Carnicer, F. Madrid-Cuevas, A. Carmona-Poyato, and R. Muñoz-Salinas, "On candidates selection for hysteresis thresholds in edge detection," *Pattern Recognition*, vol. 42, no. 7, pp. 1284–1296, 2009.
- [38] D. Martin, C. Fowlkes, and J. Malik, "Learning to detect natural image boundaries using local brightness, color, and texture cues," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 26, no. 5, pp. 530–549, 2004.
- [39] C. Lopez-Molina, B. De Baets, and H. Bustince, "Quantitative error measures for edge detection," *Pattern Recognition*, vol. 46, no. 4, pp. 1125–1139, 2013.
- [40] P. Arbelaez, M. Maire, C. Fowlkes, and J. Malik, "Contour detection and hierarchical image segmentation," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 33, pp. 898–916, 2011.



# Una nueva aproximación al concepto de similitud intervalar teniendo en cuenta la longitud de los intervalos

Humberto Bustince, Javier Fernandez, Laura de Miguel, Jose Antonio Sanz, Mikel Sesma-Sara

*Depto. de Estadística, Informática y Matemáticas*

*Universidad Pública de Navarra*

Pamplona, Spain

{bustince, fcojavier.fernandez,laura.demiguel, joseantonio.sanz, mikel.sesma}@unavarra.es

**Abstract**—En este trabajo proponemos una definición de función de equivalencia restringida intervalo-valorada que determina el grado de similitud de dos intervalos teniendo en cuenta su amplitud y utilizando órdenes admisibles. Utilizamos estas funciones para definir medidas de similitud intervalo-valoradas y discutimos algunas posibles aplicaciones.

**Index Terms**—Función de equivalencia restringida intervalo-valorada, Función de similitud intervalo-valorada, Orden admisible, Medida de similitud

## I. INTRODUCCIÓN

Los conjuntos intervalo-valorados (IVFSs) son cada vez más utilizados debido a su excelente rendimiento en múltiples aplicaciones [1]–[3], [10]. Dado que muchas de estas aplicaciones, en su versión difusa, hacen uso del concepto de medida de similitud [4], [12], las medidas de similitud intervalo-valoradas están atrayendo también un gran interés [11].

El objetivo de este trabajo es construir medidas de similitud intervalo-valoradas que, por una parte, utilicen órdenes totales (y no solo parciales) a la hora de comparar los intervalos involucrados y que, además, tengan en cuenta la amplitud de los intervalos, interpretada como una medida del grado de incertidumbre asociado a los datos. Para lograr este objetivo, consideramos nuevas definiciones de funciones de agregación y funciones de equivalencia restringida intervalo-valoradas que tienen en cuenta tanto órdenes totales como la amplitud de los intervalos.

La estructura del trabajo es la siguiente. En la Sección II presentamos algunos resultados y definiciones preliminares. En la Sección III presentamos la definición de función de equivalencia restringida intervalo-valorada y en la Sección IV, discutimos la construcción de funciones de agregación intervalo-valoradas que preservan la amplitud. La Sección V se centra en el nuevo concepto de medida de similitud intervalo-valorada basada en la amplitud. Terminamos con algunas conclusiones y referencias.

Este trabajo ha sido parcialmente financiado por el proyecto de investigación TIN2016-77356-P del Gobierno de España.

## II. PRELIMINARES

Vamos a trabajar con subintervalos cerrados del intervalo unidad. Por ello, definimos el siguiente conjunto:

$$L([0, 1]) = \{[\underline{X}, \overline{X}] \mid 0 \leq \underline{X} \leq \overline{X} \leq 1\}.$$

La amplitud de un intervalo  $X \in L([0, 1])$  se denota por  $w(X)$ . Una función intervalar  $f : (L([0, 1]))^n \rightarrow L([0, 1])$  se dice que preserva la amplitud si para todo  $X_1, \dots, X_n \in L([0, 1])$  tales que  $w(X_1) = \dots = w(X_n)$ , se tiene que  $w(f(X_1, \dots, X_n)) = w(X_i)$  para cualquier  $i \in \{1, \dots, n\}$ .

Denotamos por  $\leq_L$  una relación de orden arbitraria en  $L([0, 1])$  con  $0_L = [0, 0]$  como elemento mínimo y  $1_L = [1, 1]$  como elemento máximo. Esta relación de orden puede ser total o parcial. Si queremos hablar específicamente de un orden total, lo denotaremos por  $\leq_{TL}$ .

*Ejemplo 1:* Ejemplos de relaciones de orden en  $L([0, 1])$ .

- a) La relación de orden parcial en  $L([0, 1])$  inducida por el orden (parcial) usual en  $\mathbb{R}^2$  es:

$$[\underline{X}, \overline{X}] \lesssim_L [\underline{Y}, \overline{Y}] \text{ si } \underline{X} \leq \underline{Y} \text{ y } \overline{X} \leq \overline{Y}. \quad (1)$$

- b) Como ejemplo de orden total en  $L([0, 1])$  tenemos el de Xu y Yager (véase [14]):

$$[\underline{X}, \overline{X}] \leq_{XY} [\underline{Y}, \overline{Y}] \text{ si } \begin{cases} \underline{X} + \overline{X} < \underline{Y} + \overline{Y} \text{ o} \\ \underline{X} + \overline{X} = \underline{Y} + \overline{Y} \text{ y} \\ \overline{X} - \underline{X} \leq \overline{Y} - \underline{Y}. \end{cases} \quad (2)$$

*Definición 1:* Un orden admisible en  $L([0, 1])$  es un orden lineal  $\leq_{TL}$  que extiende el orden parcial  $\lesssim_L$ .

En este trabajo, cuando hablamos de un orden lineal entre intervalos, asumimos que es admisible. El siguiente resultado proporciona un método de construcción de órdenes admisibles.

*Proposición 1:* ([9]) Sean  $M_1, M_2 : [0, 1]^2 \rightarrow [0, 1]$  dos funciones de agregación (es decir, funciones crecientes tales que, si todas las entradas son cero, el resultado es cero y, si todas las entradas son uno, el resultado es uno) tales que, para cualesquiera  $X, Y \in L([0, 1])$ , las identidades  $M_1(\underline{X}, \overline{X}) = M_1(\underline{Y}, \overline{Y})$  y  $M_2(\underline{X}, \overline{X}) = M_2(\underline{Y}, \overline{Y})$  se

satisfacen simultáneamente si y solo si  $X = Y$ . Entonces, el orden  $\leq_{M_1, M_2}$  en  $L([0, 1])$  dado por

$$X \leq_{M_1, M_2} Y \quad \text{si} \quad \begin{cases} M_1(\underline{X}, \bar{X}) < M_1(\underline{Y}, \bar{Y}) \text{ o} \\ M_1(\underline{X}, \bar{X}) = M_1(\underline{Y}, \bar{Y}) \text{ y} \\ M_2(\underline{X}, \bar{X}) \leq M_2(\underline{Y}, \bar{Y}) \end{cases}$$

es un orden admisible en  $L([0, 1])$ .

*Ejemplo 2:*

- (i) El orden de Xu y Yager es un ejemplo de orden admisible con  $M_1(x, y) = \frac{x+y}{2}$  y  $M_2(x, y) = y$ .
- (ii) Los órdenes lexicográficos  $\leq_{lex1}$  ( $\leq_{lex2}$ ) también son ejemplos de órdenes admisibles con  $M_1(x, y) = x$  ( $M_1(x, y) = y$ ) y  $M_2(x, y) = y$  ( $M_2(x, y) = x$ ).
- (iii) En general, si, para  $\alpha \in [0, 1]$  definimos la función de agregación

$$K_\alpha(x, y) = (1 - \alpha)x + \alpha y$$

entonces, para  $\alpha, \beta \in [0, 1]$  con  $\alpha \neq \beta$ , podemos obtener el orden admisible  $\leq_{\alpha, \beta}$  tomando  $M_1(x, y) = K_\alpha(x, y)$  y  $M_2(x, y) = K_\beta(x, y)$ . Véase [9] para más detalles.

Recordemos también la definición de función de equivalencia restringida (REF) [7]

*Definición 2:* Una función  $R : [0, 1]^2 \rightarrow [0, 1]$  es una función de equivalencia restringida (REF) si:

- 1)  $R(x, y) = 0$  si y solo si  $\{x, y\} = \{0, 1\}$ ;
- 2)  $R(x, y) = 1$  si y solo si  $x = y$ ;
- 3)  $R(x, y) = R(y, x)$  para todo  $x, y \in [0, 1]$ ;
- 4) Si  $x \leq y \leq z$ , entonces  $R(x, z) \leq R(x, y)$  y  $R(x, z) \leq R(y, z)$  para todo  $x, y, z \in [0, 1]$ .

### III. FUNCIONES DE EQUIVALENCIA RESTRINGIDA INTERVALO-VALORADAS QUE PRESERVAN LA AMPLITUD

En esta sección proponemos una nueva definición de REF para datos intervalo-valorados que tiene en cuenta la amplitud de los mismos.

*Definición 3:* Sea  $\leq_L$  un orden en  $L([0, 1])$ . Una función de equivalencia restringida intervalo-valorada (IV REF) con respecto al orden  $\leq_L$  es una función  $R_{IV} : L([0, 1])^2 \rightarrow L([0, 1])$  tal que:

- 1)  $R_{IV}(X, Y) = 0_L$  si y solo si  $\{X, Y\} = \{0_L, 1_L\}$ ;
- 2)  $R_{IV}(X, X) = [1 - w(X), 1]$  para todo  $X \in L([0, 1])$ ;
- 3)  $R_{IV}(X, Y) = R_{IV}(Y, X)$  para todo  $X, Y \in L([0, 1])$ ;
- 4) Si  $X, Y, Z \in L([0, 1])$  son tales que  $X \leq_L Y \leq_L Z$  y  $w(X) = w(Y) = w(Z)$ , entonces  $R_{IV}(X, Z) \leq_L R_{IV}(X, Y)$  y  $R_{IV}(X, Z) \leq_L R_{IV}(Y, Z)$ .

La principal diferencia de esta definición respecto a su contrapartida difusa radica en el axioma 2. Dado que consideramos que la amplitud del intervalo de pertenencia de un elemento es una medida de la incertidumbre asociada al valor preciso de pertenencia, y que dicho valor preciso es un número dentro del intervalo de pertenencia, de esta forma se evita que el resultado sea menos impreciso que los datos considerados.

*Ejemplo 3:*

La función  $R_{IV} : L([0, 1])^2 \rightarrow L([0, 1])$  dada por:

$$R_{IV}(X, Y) = \left[ \max(0, 1 - |K_\alpha(X) - K_\alpha(Y)| - \frac{1}{2}(w(X) + w(Y))), \max(1 - |K_\alpha(X) - K_\alpha(Y)|, \frac{1}{2}(w(X) + w(Y))) \right]$$

es, para todo  $\alpha \in ]0, 1]$ , un ejemplo de IV REF con respecto a cualquier orden admisible.

A continuación discutimos un método de construcción de estas funciones. Para ello, necesitamos el siguiente lema previo.

*Lema 1:* Sean  $X, Y \in L([0, 1])$  intervalos tales que  $w(X) = w(Y)$ . Entonces

$$X \lesssim_L Y \quad \Leftrightarrow \quad X \leq_{TL} Y$$

para cualquier orden admisible  $\leq_{TL}$ .

*Prueba.* La demostración se sigue al tener en cuenta que dos intervalos cualesquiera de la misma amplitud son siempre comparables por medio del orden parcial  $\lesssim_L$ . Dado que todo orden admisible refina este orden parcial, se tiene el resultado. ■

*Teorema 1:* Sea  $\alpha \in ]0, 1[$ ,  $M : [0, 1]^2 \rightarrow [0, 1]$  una función de agregación simétrica e idempotente y  $R : [0, 1]^2 \rightarrow [0, 1]$  una REF. Entonces, la función  $R_{IV} : L([0, 1])^2 \rightarrow L([0, 1])$  dada por

$$R_{IV}(X, Y) = \left[ \max(0, R(K_\alpha(X), K_\alpha(Y)) - M(w(X), w(Y))), \max(R(K_\alpha(X), K_\alpha(Y)), M(w(X), w(Y))) \right] \quad (3)$$

es una IV REF con respecto a cualquier orden admisible  $\leq_{TL}$  que preserva la amplitud

*Prueba.* Por comodidad, escribimos  $\mathcal{R}$  por  $R(K_\alpha(X), K_\alpha(Y))$ , y  $\mathcal{M}$  por  $M(w(X), w(Y))$ . Entonces, la ecuación (3) se simplifica como:

$$R_{IV}(X, Y) = \left[ \max(0, \mathcal{R} - \mathcal{M}), \max(\mathcal{R}, \mathcal{M}) \right] \quad (4)$$

$$= \begin{cases} [\mathcal{R} - \mathcal{M}, \mathcal{R}], & \text{si } \mathcal{R} \geq \mathcal{M}, \\ [0, \mathcal{M}], & \text{en otro caso.} \end{cases}$$

De (4),  $R_{IV}$  está bien definido. Además,  $R_{IV}(X, Y) = 0_L$  si y solo si  $\mathcal{R} = 0$  y  $\mathcal{M} = 0$ . Pero esto ocurre si y solo si  $\{K_\alpha(X), K_\alpha(Y)\} = \{0, 1\}$ , lo que sucede si y solo si  $\{X, Y\} = \{0_L, 1_L\}$ . Luego  $w(X) = w(Y) = 0$  y tenemos la primera condición de la Definición 3.

La segunda condición de la Definición 3 se sigue al observar que  $R(K_\alpha(X), K_\alpha(X)) = 1$  y  $M(w(X), w(X)) = w(X)$ .

La simetría de  $R_{IV}$  es una consecuencia inmediata de la simetría de  $R$  y  $M$ .

La monotonía con respecto a cualquier orden admisible es clara a partir de la monotonía de  $R$ , el lema 1 y el hecho de que, si  $X \leq_{TL} Y \leq_{TL} Z$  y  $w(X) = w(Y) = w(Z)$ , entonces  $K_\alpha(X) \leq K_\alpha(Y) \leq K_\alpha(Z)$ .



Finalmente, la preservación de la amplitud  $R_{IV}$  se sigue de la Ecuación (4) y de la idempotencia de  $M$  ■

Podemos utilizar cualquier REF  $R$  y cualquier función de agregación idempotente y simétrica  $M$  en la Ecuación (3) para construir funciones de equivalencia restringida intervalo-valoradas que preserven la amplitud. De hecho, es posible simplificar la Ecuación (3) imponiendo restricciones adicionales sobre  $R$  y  $M$ .

*Corolario 1:* Sean  $\alpha \in ]0, 1[$  y  $M : [0, 1]^2 \rightarrow [0, 1]$  una función de agregación simétrica idempotente tal que

$$M(x, y) \leq \min((1 - \alpha)x + \alpha y, \alpha x + (1 - \alpha)y)$$

para cualesquiera  $x, y \in [0, 1]$ . Sea  $R : [0, 1]^2 \rightarrow [0, 1]$  una función de equivalencia restringida tal que

$$R(x, y) \geq 1 - |x - y|$$

para todo  $x, y \in [0, 1]$ . Entonces, la función  $R_{IV} : L([0, 1])^2 \rightarrow L([0, 1])$  dada por

$$R_{IV}(X, Y) = [R(K_\alpha(X), K_\alpha(Y)) - M(w(X), w(Y)), R(K_\alpha(X), K_\alpha(Y))] \quad (5)$$

es una función de equivalencia restringida intervalo-valorada con respecto a cualquier orden admisible  $\leq_{TL}$  y que preserva la amplitud.

*Prueba* Es necesario ver que

$$R(K_\alpha(X), K_\alpha(Y)) \geq M(w(X), w(Y))$$

para todo  $X, Y \in L([0, 1])$ , ya que, de este modo, la Ecuación (5) es un caso especial de la Ecuación (3).

Por nuestras hipótesis sobre  $M$  y  $R$ , es suficiente mostrar que

$$1 - |K_\alpha(X) - K_\alpha(Y)| \geq \min((1 - \alpha)w(X) + \alpha w(Y), \alpha w(X) + (1 - \alpha)w(Y)). \quad (6)$$

Supongamos que  $K_\alpha(X) \geq K_\alpha(Y)$ . Entonces

$$1 - |K_\alpha(X) - K_\alpha(Y)| = 1 - (1 - \alpha)\underline{X} - \alpha\bar{X} + (1 - \alpha)\underline{Y} + \alpha\bar{Y}$$

y como

$$\begin{aligned} 1 &\geq \bar{X} - \underline{Y} \\ &= (1 - \alpha)(\bar{X} - \underline{Y}) + \alpha(\bar{X} - \underline{Y}) \\ &= (1 - \alpha)(\bar{X} - \underline{X} + \underline{X} - \underline{Y}) \\ &\quad + \alpha(\bar{X} - \bar{Y} + \bar{Y} - \underline{Y}), \end{aligned}$$

tenemos que

$$\begin{aligned} 1 - (1 - \alpha)\underline{X} - \alpha\bar{X} + (1 - \alpha)\underline{Y} + \alpha\bar{Y} \\ \geq (1 - \alpha)(\bar{X} - \underline{X}) + \alpha(\bar{Y} - \underline{Y}), \end{aligned}$$

luego (6) se satisface.

Supongamos ahora que  $K_\alpha(X) < K_\alpha(Y)$ . Tenemos que

$$\begin{aligned} 1 - |K_\alpha(X) - K_\alpha(Y)| \\ = 1 + (1 - \alpha)\underline{X} + \alpha\bar{X} - (1 - \alpha)\underline{Y} - \alpha\bar{Y} \end{aligned}$$

y como

$$\begin{aligned} 1 &\geq \bar{Y} - \underline{X} \\ &= (1 - \alpha)(\bar{Y} - \underline{X}) + \alpha(\bar{Y} - \underline{X}) \\ &= (1 - \alpha)(\bar{Y} - \underline{Y} + \underline{Y} - \underline{X}) \\ &\quad + \alpha(\bar{Y} - \bar{X} + \bar{X} - \underline{X}), \end{aligned}$$

vemos que

$$\begin{aligned} 1 + (1 - \alpha)\underline{X} + \alpha\bar{X} - (1 - \alpha)\underline{Y} - \alpha\bar{Y} \\ \geq (1 - \alpha)(\bar{Y} - \underline{Y}) + \alpha(\bar{X} - \underline{X}), \end{aligned}$$

de donde se cumple (6) y tenemos el resultado. ■

*Corolario 2:* Consideremos la función de equivalencia restringida intervalo-valorada  $R_{IV}$  propuesta en el Corolario 1. Entonces, para todo  $X, Y \in L([0, 1])$  se tiene que

$$\begin{aligned} \min(w(X), w(Y)) &\leq w(R_{IV}(X, Y)) = M(w(X), w(Y)) \\ &\leq \min((1 - \alpha)w(X) + \alpha w(Y), \alpha w(X) + (1 - \alpha)w(Y)). \end{aligned}$$

*Prueba.* La primera desigualdad se verifica porque toda función de agregación idempotente es siempre mayor o igual que el mínimo. En cuanto a la segunda desigualdad, es una consecuencia de las hipótesis sobre  $M$  asumidas en el Corolario 1. ■

El siguiente resultado es directo.

*Lema 2:* Si  $M_1, M_2 : [0, 1]^2 \rightarrow [0, 1]$  son funciones de agregación simétricas idempotentes, entonces la función  $M : [0, 1]^2 \rightarrow [0, 1]$  dada por

$$M(x, y) = \min(M_1(x, y), M_2(x, y)),$$

para todo  $x, y \in [0, 1]$ , es una función de agregación simétrica idempotente.

*Ejemplo 4:* Vamos a construir un ejemplo específico de función de equivalencia restringida intervalo-valorada construida de acuerdo con el Corolario 1. Sea  $R^p(x, y) = 1 - |x - y|^p$ , con  $p > 0$ , que es una REF. Es claro que  $R^p(x, y) \geq R^1 = 1 - |x - y|$  para todo  $x, y \in [0, 1]$  si y solo si  $p \in [1, \infty[$ .

(i) Si tomamos  $\alpha = 1/2$  y  $M(x, y) = \frac{x+y}{2}$  obtenemos una clase de funciones de equivalencia restringida intervalo-valoradas prespecto a cualquier orden admisible:

$$\begin{aligned} R_{IV}^p(X, Y) &= \left[ R^p\left(\frac{\underline{X} + \bar{X}}{2}, \frac{\underline{Y} + \bar{Y}}{2}\right) \right. \\ &\quad \left. - \frac{w(X) + w(Y)}{2}, R^p\left(\frac{\underline{X} + \bar{X}}{2}, \frac{\underline{Y} + \bar{Y}}{2}\right) \right] \end{aligned}$$

para cualquier  $p \in [1, \infty[$ .

(ii) Si tomamos  $M(x, y) = \min(x, y)$ , obtenemos:

$$\begin{aligned} R_{IV}^{p,\alpha}(X, Y) &= [R^p(K_\alpha(X), K_\alpha(Y)) - \min(w(X), w(Y)), \\ &\quad R^p(K_\alpha(X), K_\alpha(Y))] \end{aligned}$$

para  $p \in [1, \infty[$  y  $\alpha \in ]0, 1[$ .

(iii) Sea  $\alpha \in [0, 1]$ . Es fácil observar que

$$\begin{aligned} \min((1 - \beta)x + \beta y, \beta x + (1 - \beta)y) \\ \leq \min((1 - \alpha)x + \alpha y, \alpha x + (1 - \alpha)y) \end{aligned}$$

para todo  $\beta \in [0, 1]$  tal que

$$\max(\beta, 1 - \beta) \geq \max(\alpha, 1 - \alpha).$$

Por tanto, obtenemos una clase más general que la del ítem

(ii) si tomamos  $\alpha \in ]0, 1[$  y

$$M(x, y) = \min((1 - \beta)x + \beta y, \beta x + (1 - \beta)y)$$

para  $\beta \in [\max(\alpha, 1 - \alpha), 1]$  (o equivalentemente para  $\beta \in [0, \min(\alpha, 1 - \alpha)]$ ):

$$\begin{aligned} & R_{IV}^{p, \alpha, \beta}(X, Y) \\ &= [R^p(K_\alpha(X), K_\alpha(Y)) - \min((1 - \beta)w(X) + \beta w(Y), \\ & \quad \beta w(X) + (1 - \beta)w(Y)), R^p(K_\alpha(X), K_\alpha(Y))]. \end{aligned}$$

En particular, para  $\beta = 1$  (o equivalentemente para  $\beta = 0$ ) obtenemos la clase descrita en el ítem (ii).

#### IV. FUNCIONES DE AGREGACIÓN INTERVALO-VALORADAS QUE PRESERVAN LA AMPLITUD

De cara a posibles aplicaciones, introducimos en esta sección un análisis de la posible definición de funciones de agregación intervalo-valoradas que también tengan en cuenta la amplitud de los datos a agregar. Recordamos primero la definición de función de agregación intervalo-valorada con respecto a un orden admisible arbitrario.

*Definición 4:* Sea  $n \geq 2$ . Una función de agregación intervalo-valorada ( $n$ -dimensional) en  $L([0, 1])$  con respecto a un orden  $\leq_L$  es una aplicación  $M_{IV} : (L([0, 1]))^n \rightarrow L([0, 1])$  tal que:

- (i)  $M_{IV}(0_L, \dots, 0_L) = 0_L$ .
- (ii)  $M_{IV}(1_L, \dots, 1_L) = 1_L$ .
- (iii)  $M_{IV}$  es no decreciente respecto a  $\leq_L$ .

A continuación proponemos un método de construcción de funciones de agregación intervalo-valoradas que preservan la amplitud de los intervalos a agregar.

Para ello, dada una función de agregación  $M : [0, 1]^n \rightarrow [0, 1]$ , consideramos las dos propiedades siguientes:

- (P1)  $M(cx_1, \dots, cx_n) \geq cM(x_1, \dots, x_n)$  para todo  $c \in [0, 1]$ ,  $x_1, \dots, x_n \in [0, 1]$ .
- (P2)  $M(x_1, \dots, x_n) \leq 1 - M(1 - x_1, \dots, 1 - x_n)$  para todo  $x_1, \dots, x_n \in [0, 1]$ .

*Teorema 2:* Sean  $\alpha, \beta \in [0, 1]$  con  $\beta \neq \alpha$ . Sean  $M_1, M_2 : [0, 1]^n \rightarrow [0, 1]$  dos funciones de agregación tales que  $M_1$  es estrictamente creciente,  $M_1(x_1, \dots, x_n) \geq M_2(x_1, \dots, x_n)$  para todo  $x_1, \dots, x_n \in [0, 1]$ ,  $M_1$  o  $M_2$  satisfacen la propiedad (P1) y  $M_1$  o  $M_2$  satisfacen la propiedad (P2). Entonces,  $M_{IV} : (L([0, 1]))^n \rightarrow L([0, 1])$  dada por:

$$M_{IV}(X_1, \dots, X_n) = Y, \quad \text{donde}$$

$$\begin{cases} K_\alpha(Y) = M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)), \\ w(Y) = M_2(w(X_1), \dots, w(X_n)), \end{cases}$$

para todo  $X_1, \dots, X_n \in L([0, 1])$ , es una función de agregación intervalo-valorada con respecto a  $\leq_{\alpha, \beta}$ .

Además, si  $M_2$  es idempotente, entonces  $M_{IV}$  preserva la amplitud.

*Prueba.*

Primero veamos que  $M_{IV}$  está bien definida. Tenemos

$$Y = [\underline{Y}, \overline{Y}] = [K_\alpha(Y) - \alpha w(Y), K_\alpha(Y) + (1 - \alpha)w(Y)].$$

Como  $\underline{Y} \leq \overline{Y}$ , solo debemos probar que

- 1)  $\underline{Y} \geq 0$ : Para  $\alpha = 0$  tenemos que  $\underline{Y} = M_1(\underline{X}_1, \dots, \underline{X}_n) \geq 0$  y para  $\alpha \in ]0, 1[$  tenemos que

$$\begin{aligned} K_\alpha(Y) &= M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)) \\ &\geq \alpha M_2\left(\frac{K_\alpha(X_1)}{\alpha}, \dots, \frac{K_\alpha(X_n)}{\alpha}\right) \\ &\geq \alpha M_2(w(X_1), \dots, w(X_n)) = \alpha w(Y) \end{aligned}$$

donde la primera desigualdad se sigue de que  $M_2$  satisface la propiedad (P1) y la segunda, de que  $K_\alpha(X) = (1 - \alpha)\underline{X} + \alpha\overline{X} \geq \alpha(\overline{X} - \underline{X}) = \alpha w(X)$  for all  $X \in L([0, 1])$ .

- 2)  $\overline{Y} \leq 1$ : Para  $\alpha = 1$  tenemos que  $\overline{Y} = M_1(\overline{X}_1, \dots, \overline{X}_n) \leq 1$  y para  $\alpha \in [0, 1[$  vemos que

$$\begin{aligned} & K_\alpha(Y) + (1 - \alpha)w(Y) \\ &= M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)) \\ &+ (1 - \alpha)M_2(w(X_1), \dots, w(X_n)) \\ &\leq M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)) \\ &+ (1 - \alpha)M_2\left(\frac{1 - K_\alpha(X_1)}{1 - \alpha}, \dots, \frac{1 - K_\alpha(X_n)}{1 - \alpha}\right) \\ &\leq M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)) \\ &+ M_2(1 - K_\alpha(X_1), \dots, 1 - K_\alpha(X_n)) \\ &\leq M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)) \\ &+ 1 - M_2(K_\alpha(X_1), \dots, K_\alpha(X_n)) = 1 \end{aligned}$$

donde la primera desigualdad se sigue de que  $1 - K_\alpha(X) = 1 - (1 - \alpha)\underline{X} - \alpha\overline{X} \geq (1 - \alpha)(\overline{X} - \underline{X}) = (1 - \alpha)w(X)$  for all  $X \in L([0, 1])$ , y la segunda y la tercera, de las hipótesis del Teorema.

Veamos ahora que  $M_{IV}$  es una función de agregación intervalo-valorada.

(i)  $M_{IV}(0_L, \dots, 0_L) = Y$  donde  $K_\alpha(Y) = M_1(0, \dots, 0) = 0$  y  $w(Y) = M_2(0, \dots, 0) = 0$ , luego  $Y = 0_L$ .

(ii)  $M_{IV}(1_L, \dots, 1_L) = Y$  donde  $K_\alpha(Y) = M_1(1, \dots, 1) = 1$  y  $w(Y) = M_2(0, \dots, 0) = 0$ , luego  $Y = 1_L$ .

(iii) Sea  $X_i \leq_{\alpha, \beta} Y_i$  para todo  $i = 1, \dots, n$ . Entonces  $K_\alpha(X_i) \leq K_\alpha(Y_i)$  para todo  $i = 1, \dots, n$  y hay dos posibilidades:

- 1) Existe  $j \in \{1, \dots, n\}$  tal que  $K_\alpha(X_j) < K_\alpha(Y_j)$ . Entonces

$$M_1(K_\alpha(X_1), \dots, K_\alpha(X_n)) < M_1(K_\alpha(Y_1), \dots, K_\alpha(Y_n)),$$

ya que  $M_1$  es estrictamente creciente, luego  $M_{IV}(X_1, \dots, X_n) <_{\alpha, \beta} M_{IV}(Y_1, \dots, Y_n)$ .

- 2)  $K_\alpha(X_i) = K_\alpha(Y_i)$  para todo  $i = 1, \dots, n$ . Si  $\beta > \alpha$ , entonces  $w(X_i) \leq w(Y_i)$  para todo  $i = 1, \dots, n$ , de donde  $M_2(w(X_1), \dots, w(X_n)) \leq$



$M_2(w(Y_1), \dots, w(Y_n))$ , y por tanto  $M_{IV}(X_1, \dots, X_n) \leq_{\alpha, \beta} M_{IV}(Y_1, \dots, Y_n)$ . Si  $\beta < \alpha$ , entonces  $w(X_i) \geq w(Y_i)$  para todo  $i = 1, \dots, n$ , luego  $M_2(w(X_1), \dots, w(X_n)) \geq M_2(w(Y_1), \dots, w(Y_n))$ , y  $M_{IV}(X_1, \dots, X_n) \leq_{\alpha, \beta} M_{IV}(Y_1, \dots, Y_n)$ .

Finalmente, la conservación de la amplitud se sigue fácilmente de la idempotencia de  $M_2$ . ■

**Ejemplo 5:** Una función  $M_{IV} : (L([0, 1]))^n \rightarrow L([0, 1])$  definida como en el Teorema 2, es una función de agregación intervalo-valorada que preserva la amplitud (con respecto a  $\leq_{\alpha, \beta}$ ), si, por ejemplo:

- 1) (i)  $M_1(x_1, \dots, x_n) = M_2(x_1, \dots, x_n) = \frac{x_1 + \dots + x_n}{n}$  para todo  $x_1, \dots, x_n \in [0, 1]$ , o
- 2) (ii)  $M_1(x_1, \dots, x_n) = \frac{x_1 + \dots + x_n}{n}$ ,  $M_2(x_1, \dots, x_n) = \min\{x_1, \dots, x_n\}$  para todo  $x_1, \dots, x_n \in [0, 1]$ .

## V. MEDIDAS DE SIMILITUD INTERVALO-VALORADAS QUE PRESERVAN LA AMPLITUD

A continuación proponemos una nueva definición de medida de similitud intervalo-valorada que tiene en cuenta la amplitud de los intervalos.

**Definición 5:** Sea  $\leq_L$  un orden en  $L([0, 1])$  y  $M : [0, 1]^n \rightarrow [0, 1]$  una función de agregación. Una medida de similitud intervalo-valorada asociada a  $M$  basada en la amplitud los conjuntos intervalo-valorados definidos en un referencia finito  $U$ ,  $IVFS(U)$ , y con respecto al orden  $\leq_L$  es una función  $S_M : IVFS(U) \times IVFS(U) \rightarrow L([0, 1])$  tal que, para todo  $A, B, A', B' \in IVFS(U)$ ,

$$[(SM1)] S_M(A, B) = S(B, A);$$

$$[(SM2)]$$

$$S_M(A, A) = [1 - M(w(A(u_1)), \dots, w(A(u_n))), 1];$$

$$[(SM3)] S_M(A, B) = 0_L \text{ si y solo si } \{A(u_i), B(u_i)\} = \{0_L, 1_L\} \text{ para todo } i \in \{1, \dots, n\};$$

$$[(SM4)] \text{ Si } A \subseteq A' \subseteq B' \subseteq B \text{ w.r.t. } \leq_L \text{ y } w(A(u_i)) = w(A'(u_i)) = w(B'(u_i)) = w(B(u_i)) \text{ para todo } i \in \{1, \dots, n\}, \text{ entonces } S_M(A, B) \leq_L S_M(A', B').$$

Preentamos ahora un método de construcción de estas similitudes. Recordemos que una función de agregación  $M : [0, 1]^n \rightarrow [0, 1]$  es auto-dual con respecto a la negación estándar si

$$M(x_1, \dots, x_n) = 1 - M(1 - x_1, \dots, 1 - x_n)$$

si  $x_1, \dots, x_n \in [0, 1]$ .

**Teorema 3:**

Sea  $M_{IV} : (L([0, 1]))^n \rightarrow L([0, 1])$  una función de agregación intervalo-valorada (respecto a un orden  $\leq_L$ ) tal que  $M_{IV}(X_1, \dots, X_n) = [M_L(\underline{X}_1, \dots, \underline{X}_n), M_U(\overline{X}_1, \overline{X}_n)]$  con  $M_L, M_U$  funciones de agregación y  $M_L$  auto-dual, y sea  $M_{IV}(X_1, \dots, X_n) = 0_L$  si y solo si  $X_1 = \dots = X_n = 0_L$ . Sea  $R_{IV} : L([0, 1])^2 \rightarrow L([0, 1])$  una IV REF con respecto al orden  $\leq_L$ . Entonces, la función  $S_{M_L} : IVFS(U) \times IVFS(U) \rightarrow L([0, 1])$  dada por:

$$S_{M_L}(A, B) = M_{IV}(R_{IV}(A(u_1), B(u_1)), \dots, R_{IV}(A(u_n), B(u_n)))$$

para todo  $A, B \in IVFS(U)$  es una medida de similitud intervalo-valorada asociada a  $M$  basada en la amplitud sobre  $IVFS(U)$  con respecto al orden  $\leq_L$ .

**Prueba.** (SM2) Tenemos

$$\begin{aligned} S_{M_L}(A, A) &= M_{IV}([1 - w(A(u_1)), 1], \dots, [1 - w(A(u_n)), 1]) \\ &= [M_L(1 - w(A(u_1)), \dots, 1 - w(A(u_n))), 1] \\ &= [1 - M_L(w(A(u_1)), \dots, w(A(u_n))), 1] \end{aligned}$$

(SM1), (SM3) y (SM4) son directos. ■

**Ejemplo 6:** El siguiente es un ejemplo de IV similitud basada en la amplitud con respecto a la media aritmética y el orden definido por las funciones  $K_{0.5}$  y  $K_1$  (de acuerdo con la proposición 1).

$$\begin{aligned} S_{M_1}(A, B) &= \left[ 1 - \frac{\sum_{i=1}^n |A(u_i) + \overline{A(u_i)} - B(u_i) - \overline{B(u_i)}|}{2n} \right. \\ &\quad - \frac{\sum_{i=1}^n \min(w(A(u_i)), w(B(u_i)))}{n}, \\ &\quad \left. 1 - \frac{\sum_{i=1}^n |A(u_i) + \overline{A(u_i)} - B(u_i) - \overline{B(u_i)}|}{2n} \right]. \end{aligned} \quad (7)$$

## VI. CONCLUSIONES

En este trabajo hemos presentado nuevas aproximaciones a los conceptos de función de equivalencia restringida y función de similitud en el marco intervalar teniendo en cuenta órdenes admisibles y la amplitud de los intervalos.

Estas nociones son aplicables directamente en todos aquellos problemas donde, o bien se han utilizado conjuntos intervalo-valorados, o bien se han utilizado conjuntos difusos pero existe una gran incertidumbre asociada a la construcción de los valores de pertenencia. En particular, en el futuro tenemos intención de aplicar estas nociones en problemas de de visión en estéreo.

## REFERENCES

- [1] E. Barrenechea, H. Bustince, B. De Baets, C. Lopez-Molina, Construction of interval-valued fuzzy relations with application to the generation of fuzzy edge images IEEE Transactions on Fuzzy Systems 19 (5) (2011) 819–830.
- [2] E. Barrenechea, J. Fernandez, M. Pagola, F. Chiclana, H. Bustince, Construction of interval-valued fuzzy preference relations from ignorance functions and fuzzy preference relations. Application to decision making Knowledge-Based Systems 58 (2014) 33–44.
- [3] P. Burillo, H. Bustince, Construction theorems for intuitionistic fuzzy sets, Fuzzy Sets and Systems, 84 (1996) 271–281.
- [4] H. Bustince, E. Barrenechea, M. Pagola, Relationship between restricted dissimilarity functions, restricted equivalence functions and normal  $E_N$ -functions: Image thresholding invariant, Pattern Recognition Letters 29(4) (2008) 525–536.
- [5] P. Burillo, H. Bustince, Entropy on intuitionistic fuzzy sets and on interval-valued fuzzy sets, Fuzzy Sets and Systems 78 (1996) 305–316.
- [6] H. Bustince, E. Barrenechea, M. Pagola, Image thresholding using restricted equivalence functions and maximizing the measure of similarity, Fuzzy Sets and Systems 128(5) (2007) 496–516.
- [7] H. Bustince, E. Barrenechea, M. Pagola, Restricted equivalence functions, Fuzzy Sets and Systems 157(17) (2006) 2333–2346.



- [8] H. Bustince, E. Barrenechea, M. Pagola, J. Fernández, Z. Xu, B. Bedregal, J. Montero, H. Hagra, F. Herrera, B. De Baets, A historical account of types of fuzzy sets and their relationship, *IEEE Transactions on Fuzzy Systems*, 24 (1) (2016) 179–194.
- [9] H. Bustince, J. Fernandez, , A. Kolesárová, R. Mesiar, Generation of linear orders for intervals by means of aggregation functions, *Fuzzy Sets and Systems* 220 (2013) 69–77.
- [10] H.M. Choi, G.S. Mun, J.Y. Ahn, A medical diagnosis based on interval-valued fuzzy sets, *Biomedical Engineering-Applications Basis Communications*, 24(4) (2012) 349–354.
- [11] A. Heidarzade, A new similarity measure for interval type-2 fuzzy sets: Application in fuzzy risk analysis, *International Journal of Applied Decision Sciences*, 9 (4) (2016) 400–412.
- [12] X. Liu, Entropy, distance measure and similarity measure of fuzzy sets and their relations. *Fuzzy Sets Systems* 52 (1992) 305–318.
- [13] Z. Lu, and J. Ye, Logarithmic similarity measure between interval-valued fuzzy sets and its fault diagnosis method, *Information (Switzerland)* 9 (2018) art. no. 36.
- [14] Z.S. Xu, R.R. Yager, Some geometric aggregation operators based on intuitionistic fuzzy sets, *International Journal of General Systems* 35 (2006) 417–433.



# Una generalización del algoritmo gravitacional de clústering utilizando funciones de overlap

I. Rodríguez, J. Ruiz-Aranguren, J. Fernández, H. Bustince  
 Departamento de Estadística, Informática y Matemáticas  
 Universidad Pública de Navarra, Pamplona  
 bustince@unavarra.es

Javier Armentia  
 Planetario de Pamplona  
 Pamplona, España

**Abstract**—En este trabajo consideramos una modificación del algoritmo de clúster gravitacional propuesto por Wright y utilizamos el concepto de función de overlap para mejorar su eficacia. Nuestra generalización recupera el algoritmo original. Comparamos los resultados de nuestra propuesta con los obtenidos con algoritmos usuales como el K-means o el FCM, con el objetivo de descubrir los puntos fuertes y las carencias de la nueva versión.

**Keywords**—Clúster; overlap; fuerza gravitacional

## I. INTRODUCCIÓN

La variedad en los problemas a tratar por las técnicas de clúster ha fomentado la aparición de decenas de algoritmos distintos, capaces de adaptarse a distintas situaciones y ofrecer resultados óptimos para cada caso [1]. Uno de estos algoritmos es el propuesto por W. E. Wright en 1977 [2]. Este algoritmo trata cada uno de los ejemplos sobre los que trabaja como una partícula que afecta al resto del sistema, según una adaptación de la ley de gravitación universal de Newton. Cada partícula compone inicialmente un clúster, que se van combinando a lo largo del tiempo hasta que solo queda uno.

El objetivo de este trabajo es generalizar el algoritmo de Wright utilizando funciones de overlap [3]. Nuestra generalización modifica la función fundamental que simula el movimiento de las partículas sustituyendo un término concreto por una función de overlap. Las funciones de overlap se introdujeron inicialmente en el campo difuso para tratar con el problema de determinar a cuál de dos conjuntos difusos pertenece en mayor medida una entrada dada. Sin embargo, desde sus orígenes se han aplicado con éxito en campos como los del procesamiento de imagen [4], la clasificación [5, 6] o la optimización [7].

En particular, en [7], una generalización muy competitiva del GSA, un algoritmo de optimización que también hace uso de la fuerza gravitacional, ver [8], fue propuesto, reemplazando el producto en la expresión de la fuerza por funciones de overlap (y otro tipo de funciones).

La estructura del trabajo es la siguiente. En la Sección II presentamos algunos conceptos preliminares. En la Sección III, presentamos el algoritmo de clúster gravitacional original y nuestra propuesta de generalización. La Sección IV se dedica a un estudio experimental de nuestra propuesta. Terminamos con algunas conclusiones y referencias.

## II. PRELIMINARES

### A. Funciones de Agregación

**Definición. [9]** Una función de agregación n-dimensional es una función  $M:[0,1]^n \rightarrow [0,1]$  que verifica las dos condiciones siguientes:

- M es no decreciente en cada una de sus variables;
- $M(0, \dots, 0) = 0$  y  $M(1, \dots, 1) = 1$ .

**Definición.** Sea  $M:[0,1]^n \rightarrow [0,1]$  una función de agregación n-dimensional.

- $a \in [0,1]$  es un aniquilador de M si  $M(x_1, \dots, x_n) = a$  siempre que  $a \in \{x_1, \dots, x_n\}$ .
- Si M no tiene aniquilador, M se dice estrictamente creciente si lo es en el dominio  $[0,1]^n$  como función real de n variables. Si a es un aniquilador de M, si es estrictamente creciente en el dominio  $([0, 1] \setminus \{a\})^n$ .
- M tiene divisores de cero si existen  $x_1, \dots, x_n \in [0, 1]$  tales que  $M(x_1, \dots, x_n) = 0$ .
- M es idempotente si  $M(x_1, \dots, x_n) = x$  para todo  $x \in [0, 1]$ .

Nos vamos a centrar en el caso de funciones de agregación en dimensión 2. Por ello, revisamos algunas propiedades que nos van a resultar de interés.

**Definición.** Sea M una función de agregación de dos variables.

- M es simétrica si  $M(x, y) = M(y, x)$  para cualesquiera  $x, y \in [0, 1]$ .
- M es asociativa si  $M(M(x, y), z) = M(x, M(y, z))$  para cualesquiera  $x, y, z \in [0, 1]$ .

La asociatividad permite extender las funciones de agregación bidimensionales a dimensiones mayores de una manera “razonable”. En particular, es una de las propiedades fundamentales que se demandan en la construcción de normas triangulares (t-normas).

**Definición .** Una norma triangular o t-norma es una función de agregación  $T:[0, 1]^2 \rightarrow [0, 1]$  asociativa y simétrica tal que  $T(1, x) = x$  para todo  $x \in [0, 1]$ .

Las t-normas permiten modelar intersecciones entre conjuntos difusos. Ahora bien, si estamos trabajando con solo dos elementos, la asociatividad no es en principio una propiedad que deba ser requerida. Esta idea, la de poder representar la intersección sin necesariamente requerir la asociatividad nos lleva al concepto de función de solapamiento (función de overlap) que estudiamos a continuación.

**B. Funciones de Overlap**

En esta subsección recordamos algunos conceptos y resultados presentados en [3].

**Definición** Una función  $O:[0, 1]^2 \rightarrow [0, 1]$  es una función de solapamiento si

- O es simétrica;
- $O(x, y) = 0$  si y solo si  $xy = 0$ ;
- $O(x, y) = 1$  si y solo si  $xy = 1$ ;
- O es no decreciente;
- O es continua.

Podemos presentar el siguiente resultado sobre la relación entre funciones de solapamientos y t-normas.

**Teorema.** Sea O una función de solapamiento asociativa. Entonces O es una t-norma.

En cuanto a la construcción de funciones de overlap, es posible hacerlo de forma general tal y como muestra el siguiente resultado.

**Teorema.** La función  $O:[0, 1]^2 \rightarrow [0, 1]$  es una función de solapamiento si y solo si

$$O(x, y) = f(x, y) / (f(x, y) + h(x, y))$$

Con f, h:  $[0, 1]^2 \rightarrow [0, 1]$  tales que

- f y h son simétricas;
- f es no decreciente y h es no creciente;
- $f(x, y) = 0$  si y solo si  $xy = 0$ ;
- $h(x, y) = 0$  si y solo si  $xy = 1$ ;
- f y h son continuas;

III. EL ALGORITMO DE CLÚSTER GRAVITACIONAL

**A. El Algoritmo Original**

El algoritmo de clúster gravitacional pretende hacer uso de la Ley de Gravitación Universal de Newton para llevar a cabo un proceso de clasificación no supervisado [2].

El esquema del algoritmo, tal y como figura en [2], es el siguiente:

Supongamos que tenemos n partículas  $p_1, \dots, p_n$ , para las que conocemos sus posiciones  $s_1, \dots, s_n \in \mathbb{R}^n$ . Asignamos a cada partícula  $p_i$  una masa  $m_i = 1$  para comenzar el algoritmo.

1. Fijamos dos parámetros reales positivos  $\delta$  y  $\epsilon$ .
  - Utilizamos  $\delta$  para determinar la longitud de cada paso temporal dt. En concreto, en el intervalo  $[t, t + dt]$  la partícula que se mueva más deprisa debe desplazarse una distancia  $\delta$ .
  - Si dos partículas están en algún momento a distancia menor que  $\epsilon$ , las unimos en una partícula con masa igual a la suma de las masas original y posición dada por el centro de masas de las partículas originales.
2. Inicializamos el tiempo con  $t = 0$ .
3. Repetimos los pasos (i)-(iv) siguientes hasta que solo quede una partícula.

- (i). En cada intervalo de tiempo  $[t, t + dt]$ , para cada partícula i calculamos el efecto gravitacional de las demás partículas sobre ella. En concreto:

$$g(i, t, dt) = \frac{1}{2} G \sum_{j \neq i} \frac{m_i(t)m_j(t)}{m_i(t)} \frac{s_j(t) - s_i(t)}{|s_j(t) - s_i(t)|} \frac{1}{|s_j(t) - s_i(t)|^2} dt^2 \tag{1}$$

donde G es una constante positiva.

- (ii). Para cada partícula i, su nueva posición es:  $s_i(t + dt) = s_i(t) + g(i, t, dt)$ .
- (iii). Incrementamos el tiempo de t a t + dt.
- (iv). Si dos partículas i y j están a distancia (euclídea) menor que  $\epsilon$ , se funden en una partícula como se ha explicado anteriormente.

Al final tenemos una sola partícula y, si el proceso ha durado un tiempo T, la siguiente evolución:

- De  $t_n = 0$  a  $t_{n-1}$  había n partículas.
- De  $t_{n-1}$  a  $t_{n-2}$  había n-1 partículas.
- ...
- De  $t_3$  a  $t_2$  había 3 partículas.
- De  $t_2$  a  $t_1$  había 2 partículas.

Definimos la vida relativa de la configuración de k clusters como

$$R_k = (t_k - t_{k-1}) / T$$

Tomamos como solución aquella configuración  $R_{k_0}$  con la mayor vida relativa.

Nótese que en una iteración dada puede haber varias fusiones de partículas. El caso en que en  $t_k$  se tienen k partículas y en  $t_{k-1}$  pasa a haber k-2 partículas, se puede ver como que de  $t_k$  a  $t_{k-1}$  había k partículas, de  $t_{k-1}$  a  $t_{k-2}$  pasa a haber k-1 partículas y  $t_{k-1} = t_{k-2}$ , luego  $R_{k-1} = 0$ .

Este modelo puede generalizarse reemplazando (1) por



$$g(i, t, dt) = \sum_{j \neq i} \frac{m_i(t)^p m_j(t)^q}{m_i(t)} \frac{s_j(t) - s_i(t)}{|s_j(t) - s_i(t)| |s_j(t) - s_i(t)|^2} dt^2 \quad (2)$$

con  $p, q \geq 0$ . En particular, los mejores resultados se obtienen cuando  $p = q = 0$ , obteniéndose el denominado modelo unitario de Markov

$$g(i, t, dt) = \frac{1}{m_i(t)} \sum_{j \neq i} \frac{s_j(t) - s_i(t)}{|s_j(t) - s_i(t)| |s_j(t) - s_i(t)|^2} dt^2 \quad (3)$$

Nótese que la constante  $G/2$  se ha eliminado por tratarse únicamente de un valor heredado a partir de la ley de gravitación universal de Newton que no tiene un impacto útil en nuestro algoritmo, más allá del de escalar los valores obtenidos por la función  $g$ .

### B. Generalización Usando Overlaps

En esta sección presentamos el contenido principal del trabajo: un nuevo algoritmo de clúster gravitacional que generaliza el mostrado en la sección anterior, reemplazando el factor  $1/m_i(t)$  en la ecuación (3) por un término de la forma  $O(1/m_i(t), 1)$  donde  $O: [0,1]^2 \rightarrow [0,1]$  es una función de overlap general. Ahora bien, dado que la función de overlap está definida sobre el cuadrado unidad  $[0,1]^2$ , en principio es necesaria una normalización. Esto puede hacerse considerando la función  $O(m_i^{p-1}/n^{p-1}, m_j^q/n^q)$ , con  $p, q > 0$ .

Sin embargo, dado que estamos interesados en el caso  $p, q$  próximos a cero (que es el que mejor funciona en el trabajo original), se tiene que esta función siempre es mayor o igual que  $O(1/m_i(t), 1)$ . La ecuación final a utilizar será la siguiente:

$$g(i, t, dt) = O\left(\frac{1}{m_i(t)}, 1\right) \sum_{j \neq i} \frac{s_j(t) - s_i(t)}{|s_j(t) - s_i(t)| |s_j(t) - s_i(t)|^2} dt^2 \quad (4)$$

Los overlaps que ofrecen resultados más prometedores, y que por tanto se utilizarán en la fase de experimentación son los siguientes:

$$O(x, y) = (x * y)^p \rightarrow O\left(\frac{1}{m_i}, 1\right) = \frac{1}{m_i^p} \quad (5)$$

$$O(x, y) = \frac{\sqrt{x}}{\sqrt{x} + \max(1-x, 1-y)} \rightarrow O\left(\frac{1}{m_i}, 1\right) = \frac{\sqrt{\frac{1}{m_i}}}{\sqrt{\frac{1}{m_i}} + \max\left(1 - \frac{1}{m_i}, 0\right)} \quad (6)$$

## IV. EXPERIMENTACIÓN

### A. Pruebas

Para las pruebas se utilizaron una serie de datasets sintéticos bidimensionales con el fin de comprobar en qué casos se obtienen los mejores resultados para cada uno de los overlaps. Los datasets utilizados se representan visualmente en las Figs. 1-6.

Las pruebas se realizaron utilizando tanto métricas de evaluación interna (Dunn-Index [10]) como de evaluación externa (Purity, Rand-Index [11]). Se compararon los resultados del algoritmo empleando cada uno de los overlaps

con el modelo unitario de Markov, el algoritmo K-means [12] y el Fuzzy c-Means (FCM) [13].

Para estos dos últimos algoritmos se realizaron 100 ejecuciones y se tomaron los mejores valores obtenidos, buscando evitar el problema de caer en óptimos locales. Para el algoritmo gravitacional se asignaron valores tomados de 0.01 en 0.01 en  $[0.1, 1]$  para  $\delta$ , y de  $\epsilon = 2\delta$ . Como parámetro  $p$  para (5) se utilizó el valor 20, con el objetivo de que las masas grandes se vieran muy penalizadas. En las tablas se reflejan tanto los valores medios obtenidos tras todas las ejecuciones, como los valores máximos. La columna izquierda hace referencia al dataset para el cuál se han obtenido los resultados (Figs. 1-6).

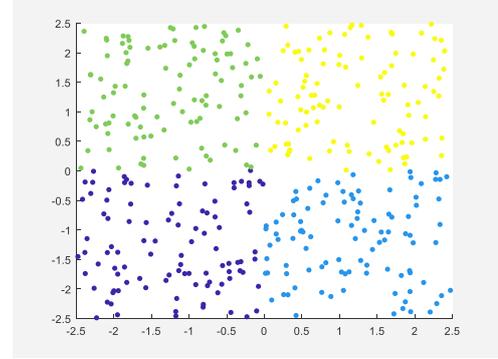


Fig. 1. Dataset "4 squares"

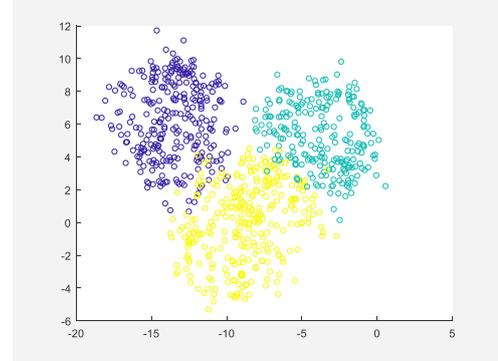


Fig. 2. Dataset "3 close circles"

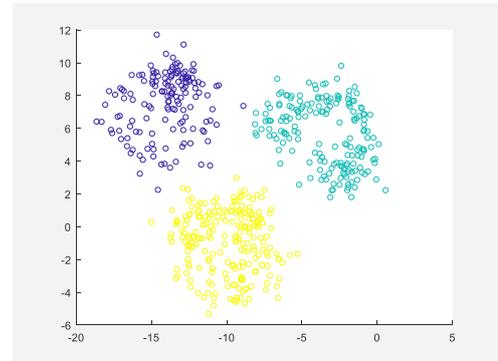


Fig. 3. Dataset "3 circles"

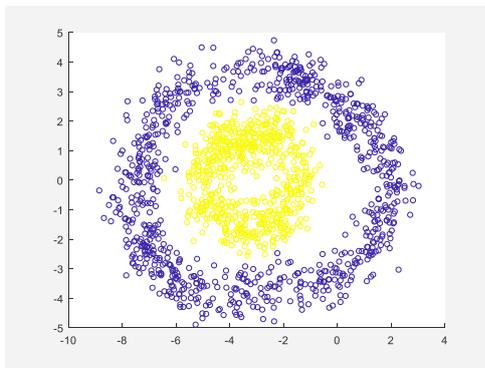


Fig. 4. Dataset "2 concentric rings"

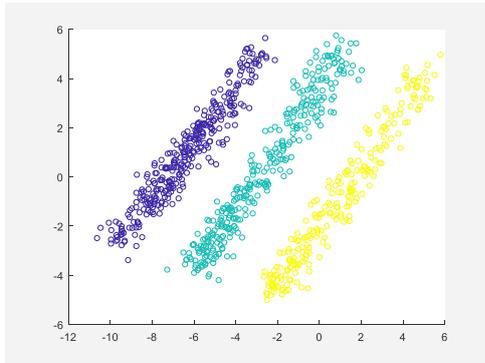


Fig. 5. Dataset "3 stripes"

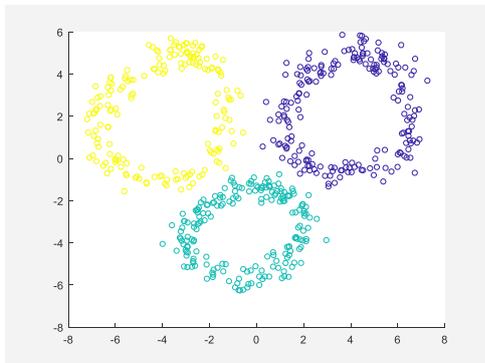


Fig. 6. Dataset "3 rings"

	Purity							K-means	FCM
	(5)		(6)		Modelo unitario				
	Mean	Max	Mean	Max	Mean	Max			
1	0,784	0,893	0,807	0,910	0,810	0,900	<b>0,988</b>	0,983	
2	0,859	0,946	0,856	<b>0,948</b>	0,852	0,920	0,901	0,901	
3	0,991	<b>0,998</b>	0,996	<b>0,998</b>	0,996	<b>0,998</b>	<b>0,998</b>	<b>0,998</b>	
4	0,577	0,628	0,622	<b>0,713</b>	0,624	0,705	0,570	0,570	
5	0,670	<b>0,928</b>	0,564	0,642	0,569	0,690	0,697	0,690	
6	0,806	<b>0,998</b>	0,788	0,916	0,784	0,916	0,960	0,960	

<sup>b</sup> Tabla 2 – Comparación de Purity entre los algoritmos para los datasets 1-6

	Rand-Index							K-means	FCM
	(5)		(6)		Modelo unitario				
	Mean	Max	Mean	Max	Mean	Max			
1	0,822	0,901	0,834	0,917	0,838	0,907	<b>0,988</b>	0,983	
2	0,843	<b>0,931</b>	0,840	<b>0,931</b>	0,836	0,902	0,884	0,884	
3	0,989	<b>0,998</b>	0,995	<b>0,998</b>	0,994	<b>0,998</b>	<b>0,998</b>	<b>0,998</b>	
4	0,507	0,532	0,533	<b>0,591</b>	0,533	0,584	0,501	0,501	
5	0,718	<b>0,905</b>	0,626	0,702	0,633	0,719	0,762	0,754	
6	0,812	<b>0,998</b>	0,741	0,900	0,735	0,900	0,949	0,949	

<sup>c</sup> Tabla 3 – Comparación de índice Rand entre los algoritmos para los datasets 1-6

B. Resultados

Lo primero que se puede observar es que no siempre existe una relación directa entre los mejores resultados para la evaluación interna y los de la externa. Esto supone un problema, dado que dificulta la búsqueda de los parámetros óptimos para el algoritmo en los casos en que carecemos de información sobre las clasificaciones a priori, que serán la mayoría.

Si nos fijamos en las medidas de evaluación externa, sin embargo, vemos que el modelo usando (6) tiende a mejorar el mejor resultado del modelo clásico, mientras que suele ofrecer valores similares en media. Por tanto, parece una alternativa razonable al mismo. En concreto, obtiene los mejores resultados de cualquier método cuando opera con datasets circulares, del mismo modo que cuando lo hace con el dataset de la Fig. 4, aunque en este caso los resultados son mediocres.

En el caso del overlap indicado en (5) tenemos que se obtienen valores con mucha varianza para la mayoría de datasets. No obstante, se obtienen resultados más que aceptables al trabajar con los dos últimos, casos en los que ninguna de las alternativas del algoritmo ofrece buenos resultados. Esto parece deberse a la gran penalización de las partículas con masas mayores. El modo de trabajo del algoritmo asegura que en todas las iteraciones, una partícula se desplazará la distancia  $\delta$ . En este caso también sucede así, pero el resto de partículas de masa mayor se desplazan distancias ínfimas, de modo que cuando se tiene un número elevado de partículas, en cada iteración tiende a moverse una sola, obteniéndose un funcionamiento similar al del algoritmo "single-linkage" [15], que opera bien con conjuntos de datos de esta forma.

	Dunn-Index							K-means	FCM
	(5)		(6)		Modelo unitario				
	Mean	Max	Mean	Max	Mean	Max			
1	0,508	0,682	0,577	0,682	0,578	0,682	<b>0,743</b>	0,736	
2	0,633	0,690	0,621	<b>0,691</b>	0,641	<b>0,691</b>	0,688	0,685	
3	0,848	0,861	0,859	0,860	0,858	0,860	<b>0,932</b>	<b>0,932</b>	
4	0,386	0,464	0,468	<b>0,497</b>	0,464	<b>0,497</b>	0,464	0,438	
5	0,378	0,579	0,442	<b>0,596</b>	0,432	0,586	0,467	0,485	
6	0,519	0,831	0,631	0,758	0,621	0,715	<b>0,874</b>	0,848	

<sup>a</sup> Tabla 1 – Comparación de índice Dunn entre los algoritmos para los datasets 1-6



## V. CONCLUSIONES Y FUTUROS TRABAJOS

Las pruebas realizadas parecen apuntar a una mejoría del funcionamiento del algoritmo cuando se utilizan los overlaps propuestos en ciertos casos concretos. Además, lo dotan de una mayor capacidad de adaptación a conjuntos de datos de forma no circular, problema con el que no pueden tratar otro tipo de técnicas.

En cualquier caso, resulta importante recalcar que nuestro caso sigue siendo una generalización del algoritmo original, por lo que siempre se puede recuperar el funcionamiento clásico.

Esta generalización abre la puerta a un estudio en mayor profundidad que permita extender la generalización empleando funciones de overlap a funciones de otro tipo, consiguiendo posiblemente comportamientos mejores. Del mismo modo, puede haber alternativas a la distancia euclidiana a tener en cuenta a la hora de calcular la distancia entre partículas. Ambas posibilidades se tendrán en cuenta para futuros trabajos.

Este trabajo ha sido parcialmente financiado por el proyecto de investigación TIN2016-77356-P (MINECO/UE/FEDER) del Gobierno de España.

## REFERENCIAS

- [1] A. Saxena, M. Prasad, A. Gupta, N. Bharill, O. Prakash Patel, A. Tiwari, E. M. Joo, D. Weiping, L. Chin-Teng, "A review of clustering techniques and developments," in *Neurocomputing*, vol. 267, pp.664-681, 2017
- [2] W. E. Wright, "Gravitational clustering", in *Pattern Recognition*, Pergamon Press 9, 1977, pp.151-166
- [3] H. Bustince, J. Fernandez, R. Mesiar, J. Montero, R. Orduna, "Overlap functions," in *Nonlinear Analysis*, vol. 72, pp.1488-1499, 2010
- [4] A. Jurio, H. Bustince, M. Pagola, A. Pradera, R. R. Yager, "Some properties of overlap and grouping functions and their application to image thresholding," in *Fuzzy Sets and Systems*, vol. 229, pp.69-90, 2013
- [5] D. Gómez, J. T. Rodríguez, J. Montero, H. Bustince, E. Barrenechea, "n-Dimensional overlap functions," in *Fuzzy Sets and Systems*, vol. 287, pp.57-75, 2016
- [6] D. Paternain, H. Bustince, M. Pagola, P. Sussner, A. Kolesrov, R. Mesiar, "Capacities and overlap indexes with an application in fuzzy rule-based classification systems," in *Fuzzy Sets and Systems*, vol. 305, pp.70-94, 2016
- [7] M. Minárová, D. Paternain, A. Jurio, J. Ruiz-Aranguren, Z. tak, H. Bustince, "Modifying the gravitational search algorithm: A functional study," in *Information Sciences*, vol. 430, pp.87-103, 2018
- [8] E. Rashedi, H. Neamabadi-Pour, S. Sariazdi, "GSA: a gravitational search algorithm," in *Information Sciences*, vol 179, pp.2232-2248, 2009
- [9] M. Grabisch, J. Marichal, R. Mesiar, E. Pap. *Aggregation Functions*, Encyclopedia of Mathematics and its Applications, vol. 127, Cambridge University Press, Cambridge, 2009.
- [10] J. C. Dunn, "Well-separated clusters and optimal fuzzy partitions," in *Journal of Cybernetics*, vol. 4, pp.95-104, 1973
- [11] D. L. Davies, D. W. Bouldin, "A cluster separation measure," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-1, pp.224-227, 1979
- [12] D. Arthur, S. Vassilvitskii, "K-means++: the advantages of careful seeding," in *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*, New Orleans, 2007
- [13] J. C. Bezdek, R. Ehrlich, W. Full, "FCM: the fuzzy c-means algorithm," in *Computer & Geosciences*, vol. 10, pp.191-203, 1984
- [14] R. Sibson, "SLINK: an optimally efficient algorithm for the single-link cluster method," in *The Computer Journal*, vol. 16, pp.30-34, 1973

# Una definición de la Integral de Choquet intervalo-valorada basada en permutaciones admisibles

Daniel Paternain, Laura De Miguel, Gustavo Ochoa, Inmaculada Lizasoain, Humberto Bustince  
*Departamento de Estadística, Informática y Matemáticas*  
Universidad Pública de Navarra, Pamplona, España  
{daniel.paternain,laura.demiguel,ochoa,ilizasoain,bustince}@unavarra.es

Radko Mesiar  
*Department of Mathematics and Descriptive Geometry, Faculty of Civil Engineering,*  
*Slovak University of Technology, Bratislava, Eslovaquia,*  
mesiar@math.sk

**Abstract**—La agregación o fusión de datos intervalo-valorados no es una tarea trivial. Esto es debido a que para aplicar determinadas funciones de agregación es necesario ordenar totalmente los datos a agregar. Para solucionar el problema del orden, en la literatura podemos encontrar soluciones basadas en el concepto de orden admisible. Tras analizar las ventajas e inconvenientes de esta propuesta, en este trabajo proponemos el concepto de permutación admisible y de integral de Choquet intervalo-valorada basada en permutaciones admisibles. Este nuevo operador nos permite agregar de una manera efectiva un conjunto de intervalos solucionando los problemas encontrados en las propuestas basadas en órdenes admisibles.

**Index Terms**—Agregación, Fusión, Integral de Choquet, intervalos, permutación admisible.

## I. INTRODUCCIÓN

La fusión de información es un paso clave en multitud de aplicaciones del mundo real, dado que en casi todas ellas es necesario combinar o fusionar en algún momento varias fuentes de información en un único valor representativo [2], [3], [11]. Ejemplos de dichas aplicaciones son la toma de decisiones multi-experto y multi-criterio, la fusión de sensores, el procesamiento digital de imágenes, la minería de datos o el aprendizaje automático, entre otros.

Cuando el proceso de fusión de información tiene un alto grado de incertidumbre asociada a los datos, las extensiones de los conjuntos difusos pueden ser muy útiles para manejar dicha incertidumbre [1], [4], [8]. Algunas extensiones que han sido muy utilizadas en la literatura son los conjuntos intervalo-valorados difusos, los conjuntos intuicionistas de Atanassov o los tipo-2. En este trabajo nos centramos en la fusión de información intervalo-valorada, ya que con una complejidad reducida, los intervalos permiten tratar la incertidumbre de manera efectiva. Ejemplos de la utilización de información intervalo-valorada pueden ser la información proveniente de los sensores, que es convertida a un intervalo de confianza teniendo en cuenta la precisión del propio instrumento; o en toma de decisiones, los intervalos pueden ser una herramienta

muy útil para los expertos cuando éstos no son capaces de asignar una puntuación exacta a una alternativa/criterio.

Sin embargo, la extensión de algunas funciones de agregación para manejar información intervalo-valorada no es trivial. Concretamente, tenemos en mente funciones como los operadores OWA o la integral de Choquet, donde es necesario ordenar los datos de entrada antes de ser fusionados. El problema surge debido a que el orden natural entre intervalos es un orden parcial y, por tanto, existen elementos incomparables que no pueden ser ordenados.

Para solucionar el problema del orden en las funciones de agregación intervalo-valoradas, en [5] se propuso una solución basada en la construcción de órdenes admisibles a partir de una pareja de funciones. Basándose en el concepto de orden admisible, en [6] se propuso una nueva definición de la integral de Choquet intervalo-valorada en la que los datos se ordenaban mediante la elección de un orden admisible. Sin embargo, aunque el problema del orden estaba solucionado, surge un nuevo problema: la elección del orden admisible más apropiado. Parece razonable pensar que si en una aplicación elegimos un mal orden admisible, los resultados de la fusión de información pueden ser contraproducentes para el resultado final de la aplicación. Se podría pensar que probando muchos órdenes admisibles se soluciona dicho problema, pero debemos tener en cuenta que: (1) podemos definir infinitos órdenes admisibles y (2) muchos órdenes admisibles son equivalentes entre sí, produciendo la misma ordenación de los datos.

Para solucionar el problema de la elección de un orden admisible concreto, en este trabajo proponemos el concepto de permutación admisible. Este concepto nos permite identificar de cuántas maneras diferentes podemos ordenar un conjunto finito de intervalos respetando en todo momento las restricciones impuestas por el orden parcial. Así, si tenemos en cuenta únicamente las permutaciones admisibles de un conjunto de intervalos podemos aislarnos de la elección de un orden admisible concreto. Basándonos en este concepto,



en este trabajo proponemos además una nueva aproximación para la integral de Choquet intervalo-valorada que tiene en cuenta todas las formas posibles de ordenar el conjunto de intervalos a ordenar y obtiene el resultado final realizando un promedio de todas ellos.

Este trabajo se organiza de la siguiente manera: en la Sección 2 recordamos los conceptos preliminares necesarios para entender el resto del trabajo. En la Sección 3 recordamos el concepto de orden admisible y de integral de Choquet basada en órdenes admisibles. En la Sección 4 proponemos el concepto de permutación admisible y de integral de Choquet basada en permutaciones admisibles y estudiamos algunas de sus propiedades. Finalmente, comentamos las conclusiones y líneas futuras en la Sección 5.

## II. PRELIMINARES

Comenzamos esta sección recordando el concepto de función de agregación en conjuntos parcialmente ordenados.

*Definición 1:* [12] Sea  $(L, \preceq)$  un conjunto parcialmente ordenado acotado con un elemento mínimo  $0_L$  y un elemento máximo  $1_L$ . Una función  $M : L^n \rightarrow L$  es una función de agregación si satisface las siguientes propiedades:

- (i)  $M(0_L, \dots, 0_L) = 0_L$  y  $M(1_L, \dots, 1_L) = 1_L$ ;
- (ii) es creciente en cada argumento, es decir, para todo  $(x_1, \dots, x_n), (y_1, \dots, y_n) \in L^n$ ,  $M(x_1, \dots, x_n) \preceq M(y_1, \dots, y_n)$  si  $x_1 \preceq y_1, \dots, x_n \preceq y_n$ .

Obsérvese que si  $L$  es el intervalo unidad junto con el orden habitual de los números reales, entonces obtenemos la definición usual de función de agregación [2], [3], [11].

En este trabajo nos centramos en la agregación de información intervalo-valorada. Por eso, tomamos  $L = L([0, 1])$  como el conjunto de todos los subintervalos cerrados del intervalo  $[0, 1]$ :

$$L([0, 1]) = \{\mathbf{x} = [x, \bar{x}] \mid 0 \leq x \leq \bar{x} \leq 1\}.$$

Nótese que  $L([0, 1])$  es un conjunto parcialmente ordenado con respecto a la relación de orden  $\leq_L$  definida de la siguiente manera: para cada  $\mathbf{x}, \mathbf{y} \in L([0, 1])$ ,

$$\mathbf{x} \leq_L \mathbf{y} \text{ si y solo si } \underline{x} \leq \underline{y} \text{ y } \bar{x} \leq \bar{y}.$$

De hecho,  $(L([0, 1]), \leq_L)$  es un retículo completo donde el elemento mínimo es  $0_L = [0, 0]$  y el máximo es  $1_L = [1, 1]$  ([10]). En este retículo, el ínfimo y supremo de cada pareja de elementos viene dado, respectivamente, por

$$\begin{aligned} \mathbf{x}_1 \wedge \mathbf{x}_2 &= [\min(\underline{x}_1, \underline{x}_2), \min(\bar{x}_1, \bar{x}_2)] \\ \mathbf{x}_1 \vee \mathbf{x}_2 &= [\max(\underline{x}_1, \underline{x}_2), \max(\bar{x}_1, \bar{x}_2)]. \end{aligned}$$

*Ejemplo 1:* Los siguientes son ejemplos de funciones de agregación intervalo-valorada:

$$\begin{aligned} \mathbf{M}_{arith}(\mathbf{x}_1, \dots, \mathbf{x}_n) &= \left[ \frac{1}{n} \sum_{i=1}^n \underline{x}_i, \frac{1}{n} \sum_{i=1}^n \bar{x}_i \right]; \\ \mathbf{M}_{min}(\mathbf{x}_1, \dots, \mathbf{x}_n) &= \left[ \min_{i=1, \dots, n} \underline{x}_i, \min_{i=1, \dots, n} \bar{x}_i \right]; \\ \mathbf{M}_{max}(\mathbf{x}_1, \dots, \mathbf{x}_n) &= \left[ \max_{i=1, \dots, n} \underline{x}_i, \max_{i=1, \dots, n} \bar{x}_i \right]. \end{aligned}$$

### A. Medidas difusas y la integral de Choquet

Antes de definir el concepto de integral de Choquet, recordamos el concepto de medida difusa (ver [14], [15]).

*Definición 2:* Sea  $X = \{1, \dots, n\}$ . Una medida difusa definida sobre  $X$  es una función  $m : 2^X \rightarrow [0, 1]$  tal que

- (i)  $m(\emptyset) = 0$  y  $m(X) = 1$ ;
- (ii) si  $E \subset F$ , entonces  $m(E) \leq m(F)$ .

*Ejemplo 2:*

- La medida difusa más pequeña viene dada por

$$m_*(E) = \begin{cases} 1 & \text{si } E = X; \\ 0 & \text{en otro caso.} \end{cases}$$

Obsérvese que para cualquier medida difusa  $m$  sobre  $X$  se cumple que  $m_*(E) \leq m(E)$ , para todo  $E \subseteq X$ .

- La medida difusa más grande viene dada por

$$m^*(E) = \begin{cases} 0 & \text{si } E = \emptyset; \\ 1 & \text{en otro caso.} \end{cases}$$

Obsérvese que para cualquier medida difusa  $m$  sobre  $X$ , se cumple que  $m(E) \leq m^*(E)$  para todo  $E \subseteq X$ .

*Definición 3:* [9] Sea  $m : 2^X \rightarrow [0, 1]$  una medida difusa. La integral de Choquet discreta de  $x_1, \dots, x_n \in [0, 1]$  con respecto a  $m$  viene dada por

$$C_m(x_1, \dots, x_n) = \sum_{i=1}^n x_{\sigma(i)} (m(\{\sigma(i), \dots, \sigma(n)\}) - m(\{\sigma(i+1), \dots, \sigma(n)\})) \quad (1)$$

donde  $\sigma : \{1, \dots, n\} \rightarrow \{1, \dots, n\}$  es una permutación tal que  $x_{\sigma(1)} \leq \dots \leq x_{\sigma(n)}$  y donde tomamos  $\{x_{\sigma(n+1)}, x_{\sigma(n)}\} = \emptyset$ .

## III. EL CONCEPTO DE ORDEN ADMISIBLE Y LA INTEGRAL DE CHOQUET BASADA EN ÓRDENES ADMISIBLES

Como hemos visto en la Sección 2, el orden  $\leq_L$  definido en  $L([0, 1])$  es un orden parcial. Esto significa que no siempre es posible comparar (ordenar) dos intervalos cualesquiera. Sin embargo, sabemos que muchas funciones de agregación, como la integral de Choquet, los operadores OWA o la integral de Sugeno, están basadas en la ordenación total de los datos de entrada. De esta manera, si queremos extender dichas funciones para agregar información intervalo-valorada, necesitamos solucionar el problema del orden.

Una primera solución a este problema fue dada en [5] mediante el concepto de orden admisible. Un orden admisible

es un orden lineal definido en  $L([0, 1])$  que refina el orden parcial  $\leq_L$ .

*Definición 4:* [5] Sea  $(L([0, 1]), \preceq)$  un conjunto parcialmente ordenado. Decimos que el orden  $\preceq$  definido en  $L([0, 1])$  es un orden admisible si

- (i)  $\preceq$  es un orden lineal en  $L([0, 1])$ ;
- (ii) para todo  $\mathbf{x}, \mathbf{y} \in L([0, 1])$  con  $\mathbf{x} \leq_L \mathbf{y}$ , se tiene  $\mathbf{x} \preceq \mathbf{y}$ .

*Ejemplo 3:* Los siguientes son ejemplos de órdenes admisibles:

- (i)  $\mathbf{x} \preceq_{Lex1}$  y (orden lexicográfico habitual en  $\mathcal{R}^2$ ) si y solo si  $\underline{x} < \underline{y}$  o  $(\underline{x} = \underline{y} \text{ y } \bar{x} \leq \bar{y})$ ;
- (ii)  $\mathbf{x} \preceq_{Lex2}$  y si y solo si  $\bar{x} < \bar{y}$  o  $(\bar{x} = \bar{y} \text{ y } \underline{x} \leq \underline{y})$ ;
- (iii)  $\mathbf{x} \preceq_{XY}$  y (orden de Xu-Yager dado en [17]) si y solo si  $\underline{x} + \bar{x} < \underline{y} + \bar{y}$  o  $(\underline{x} + \bar{x} = \underline{y} + \bar{y} \text{ y } \bar{y} - \underline{y} \leq \bar{x} - \underline{x})$ .

Una de las posibles formas de construcción de órdenes admisibles es mediante la utilización de dos funciones de agregación en  $[0, 1]$  que satisfacen determinadas propiedades. Sea  $K([0, 1]) = \{(\underline{x}, \bar{x}) \in [0, 1]^2 | \underline{x} \leq \bar{x}\}$ .

*Proposición 1:* [5] Sean  $A, B : [0, 1]^2 \rightarrow [0, 1]$  dos funciones de agregación definidas en  $[0, 1]$  tales que, para todo  $(x, y), (u, v) \in K([0, 1])$ , las igualdades  $A(x, y) = A(u, v)$  y  $B(x, y) = B(u, v)$  se cumplen simultáneamente solo si  $(x, y) = (u, v)$ . Definamos la relación  $\preceq_{A,B}$  en  $L([0, 1])$  dada por  $\mathbf{x} \preceq_{A,B} \mathbf{y}$  si y solo si

$$A(\underline{x}, \bar{x}) < A(\underline{y}, \bar{y}) \quad \text{o} \quad (2)$$

$$(A(\underline{x}, \bar{x}) = A(\underline{y}, \bar{y}) \quad \text{y} \quad B(\underline{x}, \bar{x}) \leq B(\underline{y}, \bar{y})). \quad (3)$$

Entonces,  $\preceq_{A,B}$  es un orden admisible de  $L([0, 1])$ .

#### A. La integral de Choquet basada en órdenes admisibles

A raíz de la obtención de un método de construcción de órdenes admisibles entre intervalos, en [6] los autores propusieron una nueva definición de operador OWA y de integral de Choquet intervalo-valorados basados en órdenes admisibles. La principal característica de esta nueva aproximación es que los datos de entrada son ordenados en función de un orden admisible fijado previamente. En este sentido, si fijamos los datos a agregar, podemos obtener tantas integrales de Choquet (operadores OWA) diferentes como órdenes admisibles.

*Definición 5:* Sea  $\mathbf{x}_1, \dots, \mathbf{x}_n \in L([0, 1])$  y sea  $m : 2^X \rightarrow [0, 1]$  una medida difusa. La integral de Choquet respecto al orden admisible  $\preceq_{A,B}$ , con notación  $\mathbf{C}_m^{\preceq_{A,B}}$ , viene dada por

$$\mathbf{C}_m^{\preceq_{A,B}}(\mathbf{x}_1, \dots, \mathbf{x}_n) = \sum_{i=1}^n \mathbf{x}_{\sigma_{A,B}(i)} (m(\{\sigma_{A,B}(i), \dots, \sigma_{A,B}(n)\}) - m(\{\sigma_{A,B}(i+1), \dots, \sigma_{A,B}(n)\}))$$

donde  $\sigma_{A,B} : \{1, \dots, n\} \rightarrow \{1, \dots, n\}$  es una permutación tal que

$$\mathbf{x}_{\sigma_{A,B}(1)} \preceq_{A,B} \dots \preceq_{A,B} \mathbf{x}_{\sigma_{A,B}(n)}$$

y donde tomamos  $\{\sigma_{A,B}(n), \sigma_{A,B}(n+1)\} = \emptyset$ .

Una de las principales ventajas de esta nueva definición es el hecho de que  $\mathbf{C}_m^{\preceq_{A,B}}$  generaliza la definición usual de integral de Choquet definida en  $[0, 1]$ , ya que

$$\mathbf{C}_m^{\preceq_{A,B}}([x_1, x_1], \dots, [x_n, x_n]) = [C_m(x_1, \dots, x_n), C_m(x_1, \dots, x_n)].$$

Además, si los datos de entrada son comparables con respecto al orden usual  $\leq_L$ , entonces obtenemos los mismos resultados que si aplicamos la integral de Choquet sobre los extremos inferiores y superiores.

*Proposición 2:* [6] Si  $(\underline{x}_1, \dots, \underline{x}_n), (\bar{x}_1, \dots, \bar{x}_n)$  son comonótonos, es decir, para todo  $i, j \in \{1, \dots, n\}$

$$(\underline{x}_i - \underline{x}_j)(\bar{x}_i - \bar{x}_j) \geq 0$$

entonces se cumple que  $\mathbf{C}_m^{\preceq_{A,B}}(\mathbf{x}_1, \dots, \mathbf{x}_n) = \mathbf{C}_m(\mathbf{x}_1, \dots, \mathbf{x}_n)$  para cualquier pareja admisible de funciones de agregación  $(A, B)$ .

Sin embargo, aunque el problema se resuelve parcialmente con esta aproximación, también tiene una desventaja: debemos fijar un orden admisible. Recordemos que existen infinitos órdenes admisibles y que, en general, no es sencillo identificar el orden admisible apropiado para cada problema. Por estas razones, la elección del orden admisible es un punto crucial de esta aproximación que intentamos resolver mediante el concepto de permutación admisible.

#### IV. EL CONCEPTO DE PERMUTACIÓN ADMISIBLE Y LA INTEGRAL DE CHOQUET BASADA EN PERMUTACIONES ADMISIBLES

En esta sección proponemos una nueva aproximación a la integral de Choquet intervalo-valorada que permita resolver el problema de  $\mathbf{C}_m^{\preceq_{A,B}}$ . De hecho, nuestra propuesta no se basa en la elección de un orden específico, sino que trata de tener en cuenta todos los órdenes admisibles posibles. Nótese que aunque exista la posibilidad de definir infinitos órdenes admisibles, cuando ordenamos un conjunto finito de intervalos, el número de permutaciones de dichas entradas es finito. Esto es debido a que muchos órdenes admisibles diferentes producen la misma ordenación de los datos y, por tanto, son equivalentes.

*Ejemplo 4:* Supongamos el orden admisible  $\preceq_{A,B}$  dado por  $A(x, y) = 0.5x + 0.5y$  y  $B(x, y) = 0.4x + 0.6y$ . La pareja de funciones  $(A, B)$  es admisible y, por tanto, el orden también. Supongamos ahora una segunda pareja de funciones admisibles  $(A, B')$  donde  $B'(x, y) = 0.3x + 0.7y$ . Bajo estas condiciones, si  $\mathbf{x}_1 =_{A,B} \mathbf{x}_2$ , entonces también ocurre que  $\mathbf{x}_1 =_{A,B'} \mathbf{x}_2$ ; si  $\mathbf{x}_1 \prec_{A,B} \mathbf{x}_2$ , debemos distinguir dos casos: (1) Si  $A(\underline{x}_1, \bar{x}_1) < A(\underline{x}_2, \bar{x}_2)$ , entonces también  $\mathbf{x}_1 \prec_{A,B'} \mathbf{x}_2$ ; (2) Si  $A(\underline{x}_1, \bar{x}_1) = A(\underline{x}_2, \bar{x}_2)$ , entonces por la definición de  $B'$  tenemos que  $B(\underline{x}_1, \bar{x}_1) < B(\underline{x}_2, \bar{x}_2)$  implica que  $B'(\underline{x}_1, \bar{x}_1) < B'(\underline{x}_2, \bar{x}_2)$  y por tanto  $\mathbf{x}_1 \prec_{A',B'} \mathbf{x}_2$ . De esta manera podemos ver que ambos órdenes son equivalentes. De hecho, cualquier otro orden  $\preceq_{(A,B')}$  dado por  $B'(x, y) = \alpha x + (1 - \alpha)y$  con  $\alpha < 0.5$  es equivalente al orden  $\preceq_{A,B}$ .

Además, es importante mencionar que, dados  $n$  intervalos, no todas las  $n!$  potenciales formas de ordenar dichos intervalos son admisibles. Recordemos que los órdenes admisibles refinan el orden parcial habitual  $\leq_L$ . De esta manera, dados  $\mathbf{x}_1, \dots, \mathbf{x}_n \in L([0, 1])$  y una permutación  $\sigma : \{1, \dots, n\} \rightarrow \{1, \dots, n\}$ , si  $\mathbf{x}_i <_L \mathbf{x}_j$ , entonces debemos exigir que  $\sigma^{-1}(i) < \sigma^{-1}(j)$ . Más aún, si  $\mathbf{x}_i = \mathbf{x}_j$ , entonces para cada  $k$  entre  $\sigma^{-1}(i)$  y  $\sigma^{-1}(j)$ , debemos exigir que  $\mathbf{x}_i = \mathbf{x}_{\sigma(k)} = \mathbf{x}_j$ .



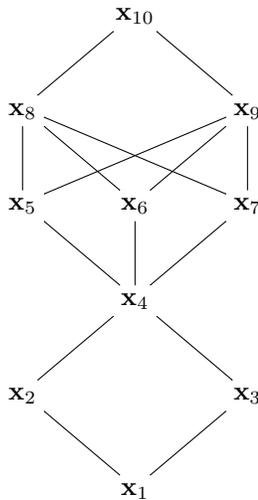
Basándonos en estas dos ideas, a continuación presentamos la definición de permutación admisible de un conjunto de intervalos.

**Definición 6:** Sean  $\mathbf{x}_1, \dots, \mathbf{x}_n \in L([0, 1])$ . Decimos que una permutación  $\sigma : \{1, \dots, n\} \rightarrow \{1, \dots, n\}$  de  $\mathbf{x}_1, \dots, \mathbf{x}_n$  es una permutación admisible respecto al orden parcial  $\leq_L$  si

- (i) para todo  $\mathbf{x}_i <_L \mathbf{x}_j$ , tenemos que  $\sigma^{-1}(i) < \sigma^{-1}(j)$ ;
- (ii) para cada  $\mathbf{x}_i$ , el conjunto  $\{\sigma^{-1}(j) | j \in \{1, \dots, n\} \text{ with } \mathbf{x}_i = \mathbf{x}_j\}$  forma un intervalo en  $\mathbb{N}$ .

Obsérvese que la primera propiedad de la Definición 6 sirve para que no se altere el orden de los intervalos que sean comparables mediante el orden parcial, mientras que la segunda propiedad sirve para que los intervalos iguales sean ordenados de manera consecutiva.

**Ejemplo 5:** Consideremos un conjunto de 10 intervalos cuyas relaciones de orden vienen dadas en el siguiente diagrama de Hasse:



Para este conjunto de intervalos existe un total de 24 permutaciones admisibles: 2 formas de ordenar  $\mathbf{x}_2$  y  $\mathbf{x}_3$ , 6 formas de ordenar  $\mathbf{x}_5$ ,  $\mathbf{x}_6$  y  $\mathbf{x}_7$  y otras 2 formas de ordenar  $\mathbf{x}_8$  y  $\mathbf{x}_9$ . Finalmente,  $24 = 2 \times 6 \times 2$ . Nótese que las restricciones impuestas a las permutaciones admisibles reducen las potenciales  $10! = 3628800$  permutaciones de 10 elementos a únicamente 24 permutaciones admisibles.

**A. La integral de Choquet basada en permutaciones admisibles**

En la sección anterior hemos visto que la propuesta de integral de Choquet intervalo-valorada se basaba en la elección de un orden admisible concreto que permite ordenar completamente el conjunto de intervalos a agregar. La propuesta que hacemos en esta sección es algo diferente ya que, en lugar de fijar un orden concreto, tiene en cuenta todas las posibles formas de ordenar dicho conjunto de intervalos. De hecho, lo que proponemos es una agregación en dos pasos: en el primero, se calcula el conjunto de permutaciones admisibles de los datos; una vez calculados, se aplica la integral de Choquet utilizando dicha permutación de datos y el resultado final se

agrega realizando un promedio que utiliza la media aritmética. De esta manera, la integral de Choquet que proponemos tiene en cuenta, de alguna manera, todas las posibles ordenaciones de los datos.

**Definición 7:** Sean  $\mathbf{x}_1, \dots, \mathbf{x}_n \in L([0, 1])$  y sea  $m : 2^n \rightarrow [0, 1]$  una medida difusa. Sean  $\sigma_1, \dots, \sigma_p : \{1, \dots, n\} \rightarrow \{1, \dots, n\}$  el conjunto de las permutaciones admisibles de  $\mathbf{x}_1, \dots, \mathbf{x}_n$ . La integral de Choquet promedio  $C_m^{arith}$  respecto a  $m$  viene dada por

$$C_m^{arith}(\mathbf{x}_1, \dots, \mathbf{x}_n) = M_{arith}(C_m^{\sigma_1}(\mathbf{x}_1, \dots, \mathbf{x}_n), \dots, C_m^{\sigma_p}(\mathbf{x}_1, \dots, \mathbf{x}_n)) \quad (4)$$

donde

$$C_m^{\sigma_j}(\mathbf{x}_1, \dots, \mathbf{x}_n) = \sum_{i=1}^n \mathbf{x}_{\sigma_j(i)} (m(\{\sigma_j(i), \dots, \sigma_j(n)\}) - m(\{\sigma_j(i+1), \dots, \sigma_j(n)\}))$$

para todo  $j \in \{1, \dots, p\}$ .

**Ejemplo 6:** Consideremos los siguientes intervalos que deber ser agregados mediante la integral de Choquet:  $\mathbf{x}_1 = [0.1, 0.9]$ ,  $\mathbf{x}_2 = [0.3, 0.5]$  y  $\mathbf{x}_3 = [0.4, 0.8]$ . Sea  $m$  una medida difusa dada por  $m(\{\emptyset\}) = 0$ ,  $m(\{1\}) = 0.3$ ,  $m(\{2\}) = 0.5$ ,  $m(\{3\}) = 0.4$ ,  $m(\{1, 2\}) = m(\{1, 3\}) = 0.6$  y  $m(\{2, 3\}) = 0.8$ .

Vamos a calcular la integral de Choquet respecto a todas las permutaciones admisibles. Obsérvese que  $\mathbf{x}_1$  no es comparable a  $\mathbf{x}_2, \mathbf{x}_3$  y que  $\mathbf{x}_2 <_L \mathbf{x}_3$ . Por tanto, existen 3 permutaciones admisibles, representadas en la siguiente matriz donde el elemento  $(i, j)$  representa  $\sigma_i(j)$ :

$$\begin{pmatrix} 1 & 2 & 3 \\ 2 & 1 & 3 \\ 2 & 3 & 1 \end{pmatrix}.$$

Ahora, tenemos que

$$\begin{aligned} C_m^{\sigma_1}(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) &= [0.3, 0.7] \\ C_m^{\sigma_2}(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) &= [0.3, 0.7] \\ C_m^{\sigma_3}(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) &= [0.27, 0.71]. \end{aligned}$$

Por último, calculamos la media aritmética de todos los valores por cada permutación admisible y tenemos que

$$C_m^{arith}(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) = [0.29, 0.703].$$

Para completar el estudio, vamos a analizar algunas de las propiedades más importantes de esta nueva integral de Choquet basada en permutaciones admisibles.

**Proposición 3:** Son ciertas las siguientes afirmaciones :

- (i)  $C_m^{arith}(\mathbf{x}, \dots, \mathbf{x}) = \mathbf{x}$  para todo  $\mathbf{x} \in L([0, 1])$ ;
- (ii)  $\inf\{\mathbf{x}_1, \dots, \mathbf{x}_n\} \leq_L C_m^{arith}(\mathbf{x}_1, \dots, \mathbf{x}_n) \leq_L \sup\{\mathbf{x}_1, \dots, \mathbf{x}_n\}$  para todo  $\mathbf{x}_1, \dots, \mathbf{x}_n \in L([0, 1])$ ;
- (iii)  $C_m^{arith}([x_1, x_1], \dots, [x_n, x_n]) = [C_m(x_1, \dots, x_n), C_m(x_1, \dots, x_n)]$  para todo  $x_1, \dots, x_n \in L([0, 1])$ ;
- (iv) si  $\mathbf{x}_1, \dots, \mathbf{x}_n$  forman una anticadena, entonces para cualquier medida difusa  $m$ ,  $C_m^{arith}(\mathbf{x}_1, \dots, \mathbf{x}_n) = M_{arith}(\mathbf{x}_1, \dots, \mathbf{x}_n)$ ;

- (v) si  $\mathbf{x}_1, \dots, \mathbf{x}_n$  forman una cadena, entonces  $\mathbf{C}_m^{arith}(\mathbf{x}_1, \dots, \mathbf{x}_n) = \mathbf{C}_m(\mathbf{x}_1, \dots, \mathbf{x}_n)$ .

En [7], [16], el concepto de monotonía ha sido sustituido por los conceptos más generales de monotonía débil y monotonía direccional. Utilizando estas generalizaciones de monotonía, el concepto de preagregación ha sido dado en [13]. Aunque la nueva definición de integral de Choquet que hemos definido en este trabajo no satisface la propiedad de monotonía tradicional, sí que satisface un tipo de monotonía direccional.

*Proposición 4:* La integral de Choquet basada en permutaciones admisibles es una preagregación respecto al vector  $\vec{r} = \vec{1}$ .

## V. CONCLUSIONES

En este trabajo hemos propuesto un nuevo mecanismo de fusión de intervalos basado en la integral de Choquet y en el concepto de permutación admisible. Esta nueva definición permite solucionar algunos problemas encontrados en soluciones anteriores, como la integral de Choquet basada en órdenes admisibles.

Como líneas futuras, nuestra intención es continuar estudiando las propiedades que cumple nuestra nueva definición y su relación con otro tipo de agregaciones intervalo-valoradas. Además, pretendemos extender esta definición a otros retículos y a otro tipo de funciones de agregación, como son los operadores OWA o la integral de Sugeno.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por MINECO, AEI/FEDER,UE bajo el proyecto TIN2016-77356-P y por los proyectos APVV-14-0013 y APVV-17-0066.

## REFERENCES

- [1] K. Atanassov. Intuitionistic fuzzy sets. *Fuzzy Sets and Systems* 20 (1986) 87-96.
- [2] G. Beliakov, H. Bustince, T. Calvo. *A Practical guide to Averaging Functions*. Studies in Fuzziness and Soft Computing 329, Springer, 2016.
- [3] G. Beliakov, A. Pradera, T. Calvo. *Aggregation Functions: A Guide for Practitioners*. Studies in Fuzziness and Soft Computing 221, Springer, 2007.
- [4] H. Bustince, Interval-valued fuzzy sets in soft computing. *International Journal of Computational Intelligent Systems* 3 (2010) 215-222.
- [5] H. Bustince, J. Fernandez, A. Kolesárová, R. Mesiar, Generation of linear orders for intervals by means of aggregation functions. *Fuzzy Sets and Systems* 220 (2013) 69-77.
- [6] H. Bustince, M. Galar, B. Bedregal, A. Kolesárová, R. Mesiar, A New Approach to Interval-Valued Choquet Integrals and the Problem of Ordering in Interval-Valued Fuzzy Set Applications. *IEEE Transactions on Fuzzy Systems* 21 (2013), 1150-1162.
- [7] H. Bustince, J. Fernandez, A. Kolesárová, R. Mesiar. Directional monotonicity of fusion functions. *European Journal of Operational Research* 244 (2015) 300-308.
- [8] H. Bustince, E. Barrenechea, M. Pagola, J. Fernandez, Z. Xu, B. Bedregal, J. Montero, H. hagrás, F. Herrera, B. De Baets. A Historical Account of Types of Fuzzy Sets and Their Relationships. *IEEE Transactions on Fuzzy Systems* 24 (2016) 179-194.
- [9] G. Choquet, Theory of capacities. *Annales de l'Institute Fourier* 5 (1954) 131-292.
- [10] G. Deschrijver, C. Cornelus, E.E. Kerre. On the representation of intuitionistic fuzzy t-norms and t-conorms. *IEEE Transactions on Fuzzy Systems* 12 (2004) 45-61.
- [11] M. Grabisch, J.-L. Marichal, R. Mesiar, E. Pap, *Aggregation Functions*. Cambridge University Press, 2009.
- [12] M. Komorníková, R. Mesiar. Aggregation functions on bounded partially ordered sets and their classification. *Fuzzy Sets and Systems* 175 (2011) 48-56.
- [13] G. Lucca, J. Sanz, G. P. Dimuro, B. Bedregal, R. Mesiar, A. Kolesárová, H. Bustince. Preaggregation Functions: Construction and an Application. *IEEE Transactions on Fuzzy Systems* 24 (2016) 260-272.
- [14] D. Paternain, H. Bustince, M. Pagola, P. Sussner, A. Kolesárová and R. Mesiar. Capacities and overlap indexes with an application in fuzzy rule-based classification systems. *Fuzzy Sets and Systems* 305 (2016) 70-94.
- [15] V. Torra, Y. Narukawa and M. Sugeno, Eds., *Non-Additive Measures, Theory and Applications (Studies in Fuzziness and Soft Computing Series 310)*, Springer, 2014.
- [16] T. Wilkin, G. Beliakov. Weakly Monotonic Averaging Functions. *International Journal of Intelligent Systems* 30 (2015) 144-169.
- [17] Z. S. Xu, R. R. Yager. Some geometric aggregation operators based on intuitionistic fuzzy sets. *International Journal of General Systems* 35 (2006) 417-433.



# Aggregation on relaxed indistinguishability operators based on different triangular norms

Tomasa Calvo Sánchez

University of Alcalá

Email: tomasa.calvo@uah.es

Pilar Fuster-Parra

University of Balearic Islands

Email: pilar.fuster@uib.es

Oscar Valero

University of Balearic Islands

Email: o.valero@uib.es

**Abstract**—We consider the aggregation problem of relaxed  $T_i$ -indistinguishability operators where each member of the collection to be merged is a relaxed indistinguishability operator with respect to a different t-norm  $T_i$ . Thus we provide sufficient conditions to merge a collection such an indistinguishability operators. Moreover, we give a characterization of those functions that allow to merge a collection of relaxed indistinguishability operators into a new one whenever all involved t-norms are continuous, Archimedean and strict. Namely, we characterize these functions in terms of the additive generator of the involved t-norms and those functions that transforms  $n$ -dimensional triangular triplets of the non-negative real line into a 1-dimensional triplet of the non-negative real line.

## I. INTRODUCTION

Aggregation functions constitute an important tool in the field of information fusion (see [4], [5], [7]). The information can be given by means of fuzzy relations what depends on different applications (see, for instance, [1], [13], [19], [26], [27], [34]). Sometimes the aggregation procedure used to take a working decision requires that the nature of the aggregated data be preserved. In the last decades, the problem of aggregating fuzzy relations has grown considerably among researchers in fuzzy mathematics (see [14], [21], [22], [28], [29], [31]). Motivated by the preceding fact, in [9], [10], we have carried out the study of the class preservation of relaxed  $T$ -indistinguishability operators by means of aggregation.

Let us recall that, on account of [32], a  $T$ -indistinguishability operator on a (non-empty) set  $X$  is a fuzzy relation  $E : X \times X \rightarrow [0, 1]$  satisfying for all  $x, y, z \in X$  the following: (i)  $E(x, x) = 1$ , (ii)  $E(x, y) = E(y, x)$ , and (iii)  $T(E(x, y), E(y, z)) \leq E(x, z)$ . In general, a  $T$ -indistinguishability operator allows to classify objects when a measure presents some kind of uncertainty. They are also known as measures of similarity, in fact, the greater  $E(x, y)$  the most similar are  $x$  and  $y$ . We assume that the reader is familiar with the basics of t-norms (see, for instance, [22]).

In the literature, we can find several authors that have analyzed the functions that allows to merge a collection of indistinguishability operators into a single one (see [28], [29], [31]). In particular, in [28] a characterization of those functions that aggregate indistinguishability operators have been given in terms of triangle triplets (compare [30]). Recently, the aforementioned description of the functions that aggregates indistinguishability operators have been extended by Mayor and Recasens in [24], now, in terms of  $T$ -triangular triplets.

Inspired by [24], recent results on the aggregation of relaxed  $T$ -indistinguishability operators have been developed in [9]. Now, let us recall that a relaxed  $T$ -indistinguishability operator on a (non-empty) set  $X$  is a fuzzy relation  $E : X \times X \rightarrow [0, 1]$  verifying for all  $x, y, z \in X$  the following properties: (i)  $E(x, y) = E(y, x)$  and (ii)  $T(E(x, y), E(y, z)) \leq E(x, z)$ . A relaxed  $T$ -indistinguishability operator  $E$  on a nonempty set  $X$  will be called a relaxed  $T$ -equality provided that it satisfies the following additional property for any  $x, y, z \in X$ : (i')  $E(x, y) = E(x, x) = E(y, y) \Leftrightarrow x = y$ .

There exist another measures very useful to classify objects that are related to (relaxed)  $T$ -indistinguishability operators, the so-called (extended) pseudo-metrics (see [12]). However, the extended pseudo-metrics are measures of dissimilarity. In the recent literature, different techniques to generate extended pseudo-metrics from indistinguishability operators, and vice-versa, have been developed (see, for example, [2], [3], [17], [20], [22], [25], [31], [33]).

It is clear that  $T$ -indistinguishability operators are relaxed  $T$ -indistinguishability operators. Nevertheless, the following is an instance of relaxed and partial indistinguishability operator that is not an indistinguishability one.

**Example 1.** Let  $\Sigma$  be a non-empty alphabet. Denote by  $\Sigma^\infty$  the set of all finite and infinite sequences over  $\Sigma$ . Given  $v \in \Sigma^\infty$  denote by  $l(v)$  the length of  $v$ . Thus  $l(v) \in \mathbb{N} \cup \{\infty\}$  for all  $v \in \Sigma^\infty$ . Moreover, if  $\Sigma_F = \{v \in \Sigma^\infty : l(v) \in \mathbb{N}\}$  and  $\Sigma_\infty = \{v \in \Sigma^\infty : l(v) = \infty\}$ , then  $\Sigma^\infty = \Sigma_F \cup \Sigma_\infty$  and we will write  $v = v_1 v_2 \dots v_{l(v)}$  and  $w = w_1 w_2 \dots$  whenever  $v \in \Sigma_F$  and  $w \in \Sigma_\infty$ , respectively.

Next, given  $x, y \in \Sigma_\infty$ , denote by  $l(x, y)$  the longest common prefix of  $x$  and  $y$  (of course if  $x$  and  $y$  have not a common prefix then  $l(x, y) = 0$ ).

Define the fuzzy relation  $E_\Sigma$  on  $\Sigma^\infty \times \Sigma^\infty$  by  $E_\Sigma(u, v) = 1 - 2^{-l(u, v)}$  for all  $u, v \in \Sigma^\infty$ . Then it is a simple matter to check that  $E_\Sigma$  is a relaxed  $T_{\min}$ -indistinguishability operator on  $\Sigma^\infty$ . In fact, it is a relaxed  $T_{\min}$ -equality on  $\Sigma^\infty$ . Note that  $T_{\min}$  denotes the minimum t-norm.

Note that  $E_\Sigma$  is not a indistinguishability operator, since  $E_\Sigma(u, u) = 1 \Leftrightarrow u \in \Sigma_\infty$ .

As we have mentioned before, the study of the class preservation of relaxed  $T$ -indistinguishability operators by means of aggregation was carried out in [9], [10]. Now we focus our attention on the similar preservation problem when

a collection of  $T_i$ -indistinguishability operators belonging to the aforesaid class under consideration and in such a way that each member of the collection to be merged is a relaxed indistinguishability operator with respect to different t-norm  $T_i$  and all of them are defined on the same set.

Thus, in this work, we provide sufficient conditions to merge a collection of relaxed indistinguishability operators in Section II. Concretely, we see that a dominance condition is sufficient to guarantee that a function aggregates relaxed  $T_i$ -indistinguishability operators. Furthermore, we give a characterization of those functions that allow to merge a collection of relaxed indistinguishability operators into a new one whenever all involved t-norms are continuous, Archimedean and strict. Namely, we characterize these functions in terms of the additive generator of the involved t-norms and those functions that transforms  $n$ -dimensional triangular triplets of the positive real line into a 1-dimensional triplet of the positive real line. Finally, in Section III, some conclusions are given and future work is proposed.

## II. THE AGGREGATION OF RELAXED $T_i$ -INDISTINGUISHABILITY OPERATORS

First of all we introduce the notion of relaxed  $T_i$ -indistinguishability operator aggregation function as follows.

**Definition 1.** A function  $F : [0, 1]^n \rightarrow [0, 1]$  aggregates relaxed  $T_i$ -indistinguishability operators into a relaxed  $T$ -indistinguishability operator if  $F(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operators on  $X$  for any set  $X$  and any collection  $(E_1, \dots, E_n)$  of relaxed  $T_i$ -indistinguishability operators on  $X$ , where  $F(E_1, \dots, E_n)$  is the fuzzy binary relation given by  $F(E_1, \dots, E_n)(x, y) = F(E_1(x, y), \dots, E_n(x, y))$ .

Notice that Definition 1 extends the notion given in [9]. In the light of the preceding concept we have the next result.

**Proposition 1.** Let  $T$  be a t-norm and let  $E_i, i = 1, \dots, n$ , be a collection of relaxed  $T_i$ -indistinguishability operators. If a function  $F : [0, 1]^n \rightarrow [0, 1]$  is increasing and satisfies  $T(F(a), F(b)) \leq F(T_1(a_1, b_1), \dots, T_n(a_n, b_n))$  for all  $\mathbf{a}, \mathbf{b} \in [0, 1]^n$ , then  $F(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operator.

*Proof.* To prove that  $F(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operator, we only need to show the  $T$ -transitivity condition of  $F(E_1, \dots, E_n)$  because the symmetry follows directly from the symmetry of each  $E_i$  relaxed  $T_i$ -indistinguishability operator.

Now, as each  $E_i$  is a relaxed  $T_i$ -indistinguishability operator we have that  $T_i(E_i(x, y), E_i(y, z)) \leq E_i(x, z)$  for all  $i = 1, \dots, n$ . Since  $F$  is an increasing function we get  $F(T_1(E_1(x, y), E_1(y, z)), \dots, T_n(E_n(x, y), E_n(y, z))) \leq F(E_1(x, z), \dots, E_n(x, z))$ .

Calling  $\mathbf{a} = (E_1(x, y), \dots, E_n(x, y))$ ,  $\mathbf{b} = (E_1(y, z), \dots, E_n(y, z))$  and  $\mathbf{c} = (E_1(x, z), \dots, E_n(x, z))$  we obtain that  $T(F(E_1, \dots, E_n)(x, y), F(E_1, \dots, E_n)(y, z)) = T(F(E_1(x, y), \dots, E_n(x, y)), F(E_1(y, z), \dots, E_n(y, z))) =$

$$\begin{aligned} T(F(a), F(b)) &\leq F(T_1(a_1, b_1), \dots, T_n(a_n, b_n)) = \\ &F(T_1(E_1(x, y), E_1(y, z)), \dots, T_n(E_n(x, y), E_n(y, z))) \leq \\ &F(E_1(x, z), \dots, E_n(x, z)). \end{aligned}$$

Therefore,  $F(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operator.  $\square$

According to the previous result, it seems natural to wonder whether the converse of Proposition 1 is true in general. However, the next example, which was given in [9], shows that there are relaxed  $T_i$ -indistinguishability aggregation functions that are not increasing.

**Example 2.** Denote by  $T_D$  the Drastic t-norm. Consider the function  $F : [0, 1]^2 \rightarrow [0, 1]$  defined by

$$F(\mathbf{a}) = \begin{cases} 1, & \mathbf{a} = (1, 1) \\ 0, & \mathbf{a} = (1/2, 1/2) \\ 1/2, & \text{otherwise} \end{cases}$$

for all  $\mathbf{a} \in [0, 1]^2$ . It is not hard to check that  $F$  aggregates  $T_D$ -indistinguishability operators. However  $F$  is not an increasing function due to  $F(1/2, 0) \leq F(0, 0)$ .

When the collection of  $n + 1$ -t-norms  $T, T_i$ , are such that  $T \leq T_i$ , for all  $i = 1, \dots, n$ , the following result can be stated.

**Proposition 2.** Let  $T$  be a t-norm and let  $E_i, i = 1, \dots, n$ , be a collection of relaxed  $T_i$ -indistinguishability operators. If  $T \leq T_i$  for all  $i = 1, \dots, n$ , then  $T(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operator.

*Proof.* First of all we show the transitivity condition. On the one hand, by the commutativity and associativity of  $T$ , we have that

$$T(T(E_1(x, y), \dots, E_n(x, y)), T(E_1(y, z), \dots, E_n(y, z))) = T(T(E_1(x, y), E_1(y, z)), \dots, T(E_n(x, y), E_n(y, z))).$$

On the other hand, the monotony of  $T$  and the fact that  $T \leq T_i$  provide that

$$T(T(E_1(x, y), E_1(y, z)), \dots, T(E_n(x, y), E_n(y, z))) \leq T(T_1(E_1(x, y), E_1(y, z)), \dots, T_n(E_n(x, y), E_n(y, z))).$$

Since  $T_i(E_i(x, y), E_i(y, z)) \leq E_i(x, z)$  for all  $i = 1, \dots, n$  we have that

$$T(T_1(E_1(x, y), E_1(y, z)), \dots, T_n(E_n(x, y), E_n(y, z))) \leq T(E_1(x, z), \dots, E_n(x, z)).$$

It follows that

$$T(T(E_1, \dots, E_n)(x, y), T(E_1, \dots, E_n)(y, z)) \leq T(E_1, \dots, E_n)(x, z).$$

This means that  $T(E_1, \dots, E_n)$  is a  $T$ -transitive relation. As the symmetry of this relation is always guaranteed by the symmetry of  $T$ , we conclude that  $T(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operator.  $\square$

As an example, in the spirit of the above proposition, we can choose  $T = T_D$  and  $T_i = T_P$  for all  $i = 1, \dots, n$ . Then, by Proposition 2,  $T_D(E_1, \dots, E_n)$  is a relaxed  $T_D$ -indistinguishability operator when  $E_i$  is a collection of  $T_P$ -indistinguishability operators, since  $T_D \leq T_P$ .



In order to introduce the announced characterization of those functions that merge relaxed  $T_i$ -indistinguishability operators, we need to recall the following notion which was provided in [6].

**Definition 2.** A triplet  $(a, b, c) \in [0, \infty]^3$  is said to be (1-dimensional) triangular if and only if  $a \leq b + c$ ,  $b \leq a + c$  and  $c \leq a + b$ . Being  $\mathbf{a}, \mathbf{b}, \mathbf{c} \in [0, \infty]^n$ ,  $n \geq 1$ , we say that  $(\mathbf{a}, \mathbf{b}, \mathbf{c})$  is a ( $n$ -dimensional) triangular triplet if  $(a_i, b_i, c_i)$  is a triangular triplet for all  $i = 1, \dots, n$ , where  $\mathbf{a} = (a_1, \dots, a_n)$ ,  $\mathbf{b} = (b_1, \dots, b_n)$  and  $\mathbf{c} = (c_1, \dots, c_n)$ .

Taking into account the preceding notion we provide the following characterization.

**Theorem 1.** Let  $T, T_1, \dots, T_n$  be strict and continuous Archimedean  $t$ -norms. The following assertions are equivalent:

- 1) A function  $F : [0, 1]^n \rightarrow [0, 1]$  aggregates a collection of  $n$  relaxed  $T_i$ -indistinguishability operators  $E_i$  into a relaxed  $T$ -indistinguishability operator.
- 2) There exists a function  $G : [0, +\infty]^n \rightarrow [0, +\infty]$  which transforms  $n$ -dimensional triangular triplets into 1-dimensional triangular triplets and satisfies

$$G = t \circ F \circ (t_1^{-1} \times \dots \times t_n^{-1}),$$

where  $t$  and  $t_i$  are additive generators of  $t$ -norms  $T$  and  $T_i$ , respectively.

*Proof.* (1)  $\rightarrow$  (2) Let us suppose that  $F$  aggregates a collection of relaxed  $T_i$ -indistinguishability operators into a relaxed  $T$ -indistinguishability operator. We have to prove that  $G$  transforms  $n$ -dimensional triangular triplets into 1-dimensional triangular triplets. To this end, assume that  $(\mathbf{a}, \mathbf{b}, \mathbf{c}) \in [0, \infty]^n$  is a  $n$ -dimensional triplet. Define the fuzzy relations  $E_i$ ,  $i = 1, \dots, n$ , on a non-empty set  $X = \{x, y, z\}$  (of different elements) by  $E_i(x, y) = E_i(y, x) = t_i^{-1}(b_i)$ ,  $E_i(x, z) = E_i(z, x) = t_i^{-1}(a_i)$ ,  $E_i(y, z) = E_i(z, y) = t_i^{-1}(c_i)$ ,  $E_i(x, x) = E_i(y, y) = E_i(z, z) = 1$ . It is not hard to check that each  $E_i$  is a relaxed  $T_i$ -indistinguishability operator, since  $(\mathbf{a}, \mathbf{b}, \mathbf{c})$  is a  $n$ -dimensional triplet. Next, let us prove that  $(G(\mathbf{a}), G(\mathbf{b}), G(\mathbf{c}))$  is a 1-dimensional triangular triplet.

Since  $F$  aggregates the collection of relaxed  $T_i$ -indistinguishability operators  $E_i$  into a relaxed  $T$ -indistinguishability operator we have that

$$\frac{T(F(E_1, \dots, E_n)(x, y), F(E_1, \dots, E_n)(y, z))}{F(E_1, \dots, E_n)(x, z)} \leq$$

It follows that

$$t^{-1}(t \circ F(E_1, \dots, E_n)(x, y)) + t \circ (F(E_1, \dots, E_n)(y, z)) \leq F(E_1, \dots, E_n)(x, z).$$

Whence we deduce that

$$t \circ (F(E_1, \dots, E_n)(x, y)) + t \circ (F(E_1, \dots, E_n)(y, z)) \geq t(F(E_1, \dots, E_n)(x, z)).$$

The fact that  $E_i(x, y) = t^{-1}(b_i)$ ,  $E_i(x, z) = t^{-1}(a_i)$  and  $E_i(y, z) = t^{-1}(c_i)$  provides that

$$t \circ (F(t_1^{-1}(b_1), \dots, t_n^{-1}(b_n))) + t \circ (F(t_1^{-1}(c_1), \dots, t_n^{-1}(c_n))) \geq t \circ (F(t_1^{-1}(a_1), \dots, t_n^{-1}(a_n))).$$

Hence we conclude that  $G(\mathbf{a}) \leq G(\mathbf{b}) + G(\mathbf{c})$  and, thus, that  $G$  transforms a  $n$ -dimensional triangular triplet into a 1-dimensional triangular triplet.

(2)  $\rightarrow$  (1) Assuming that  $G$  transforms  $n$ -dimensional triangular triplets into 1-dimensional triangle triplets, we must prove that  $F(E_1, \dots, E_n)$  is a relaxed  $T$ -indistinguishability operator for all collection  $E_i$ ,  $i = 1, \dots, n$ , of relaxed  $T_i$ -indistinguishability operators. To this end, consider a collection  $E_i$ ,  $i = 1, \dots, n$ , of relaxed  $T$ -indistinguishability operators on a non-empty set  $X$ . Then, for each  $x, y, z \in X$ , we set  $E_i(x, y) = E_i(y, x) = a_i$ ,  $E_i(y, z) = E_i(z, y) = b_i$ , and  $E_i(x, z) = E_i(z, x) = c_i$ . Since  $T_i(E_i(x, y), E_i(y, z)) \leq E_i(x, z)$ ,  $T_i(E_i(x, z), E_i(z, y)) \leq E_i(x, y)$  and  $T_i(E_i(y, x), E_i(x, z)) \leq E_i(y, z)$  we have that  $t_i(a_i) + t_i(b_i) \geq t_i(c_i)$ ,  $t_i(b_i) + t_i(c_i) \geq t_i(a_i)$  and  $t_i(a_i) + t_i(c_i) \geq t_i(b_i)$  and, thus, that  $(t_i(a_i), t_i(b_i), t_i(c_i))$  is a 1-dimensional triangle triplet. So  $(\mathbf{t}(\mathbf{a}), \mathbf{t}(\mathbf{b}), \mathbf{t}(\mathbf{c}))$  is a  $n$ -dimensional triangle triplet. The fact that  $G$  transforms  $n$ -dimensional triangular triplets into 1-dimensional triangle triplets provides that  $(G(\mathbf{t}(\mathbf{a})), G(\mathbf{t}(\mathbf{b})), G(\mathbf{t}(\mathbf{c})))$  is a 1-dimensional triangle triplet, where  $\mathbf{t}(\mathbf{a}) = (t_1(a_1), \dots, t_n(a_n))$ ,  $\mathbf{t}(\mathbf{b}) = (t_1(b_1), \dots, t_n(b_n))$  and  $\mathbf{t}(\mathbf{c}) = (t_1(c_1), \dots, t_n(c_n))$ . Thus  $G(\mathbf{t}(\mathbf{a})) \leq G(\mathbf{t}(\mathbf{b})) + G(\mathbf{t}(\mathbf{c}))$ ,  $G(\mathbf{t}(\mathbf{b})) \leq G(\mathbf{t}(\mathbf{a})) + G(\mathbf{t}(\mathbf{c}))$  and  $G(\mathbf{t}(\mathbf{c})) \leq G(\mathbf{t}(\mathbf{a})) + G(\mathbf{t}(\mathbf{b}))$ .

Since  $G = t \circ F \circ (t_1^{-1} \times \dots \times t_n^{-1})$  we have

$$\begin{aligned} t(F(\mathbf{a})) &= G(\mathbf{t}(\mathbf{a})) \leq G(\mathbf{t}(\mathbf{b})) + G(\mathbf{t}(\mathbf{c})) \\ &= t(F(\mathbf{b})) + t(F(\mathbf{c})). \end{aligned}$$

From the preceding inequality we deduce that

$$F(\mathbf{a}) \geq t^{-1}(t(F(\mathbf{b})) + t(F(\mathbf{c}))) = T(F(\mathbf{b}), F(\mathbf{c})).$$

Therefore we obtain that

$$\frac{T(F(E_1, \dots, E_n)(z, y), F(E_1, \dots, E_n)(x, z))}{F(E_1, \dots, E_n)(x, y)} \leq$$

Similarly we can show that

$$\frac{T(F(E_1, \dots, E_n)(x, y), F(E_1, \dots, E_n)(y, z))}{F(E_1, \dots, E_n)(x, z)} \leq$$

and

$$\frac{T(F(E_1, \dots, E_n)(y, x), F(E_1, \dots, E_n)(x, z))}{F(E_1, \dots, E_n)(y, z)} \leq$$

Moreover,  $F(E_1, \dots, E_n)(x, y) = F(E_1, \dots, E_n)(y, x)$  due to every  $E_i$  is a relaxed  $T_i$ -indistinguishability operator. Consequently, we conclude that  $F$  aggregates relaxed  $T_i$ -indistinguishability operators into a relaxed  $T$ -indistinguishability operator.  $\square$

In order to finish the paper we recall two pertinent properties of those functions that transform  $n$ -dimensional triangular triplets into 1-dimensional triangular triplets (see [6]).

**Proposition 3.** Consider a function  $G : [0, \infty]^n \rightarrow [0, \infty]$ ,  $n \geq 1$ . Then:

- i) If  $G$  transforms  $n$ -dimensional triangular triplets into 1-dimensional triangular triplets, then it is subadditive.
- ii) If  $G$  is increasing and subadditive, then it transforms  $n$ -dimensional triangular triplets into 1-dimensional triangular triplets.

Taking into account Propositions 1 and 3 we can state the next result.

**Corollary 1.** Let  $T, T_1, \dots, T_n$  be strict and continuous Archimedean  $t$ -norms ( $n \geq 1$ ) and let  $F : [0, 1]^n \rightarrow [0, 1]$  be an increasing function. Then the following assertions are equivalent:

- 1)  $F : [0, 1]^n \rightarrow [0, 1]$  aggregates relaxed  $T_i$ -indistinguishability operators into a relaxed  $T$ -indistinguishability operator.
- 2) The function  $G : [0, +\infty]^n \rightarrow [0, +\infty]$  given by  $G = t \circ F \circ (t_1^{-1} \times \dots \times t_n^{-1})$  is subadditive.

*Proof.* (1)  $\rightarrow$  (2) Taking into account Theorem 1 we know that  $G$  transforms  $n$ -dimensional triangular triplets into a 1-dimensional triangular triplet and, in addition, from Proposition 3 we can ensure that  $G$  is a subadditive function.

(2)  $\rightarrow$  (1). The monotony of  $F$  yields that  $G$  is increasing. Proposition 3 guarantees that the function  $G$  transforms  $n$ -dimensional triangular triplets into 1-dimensional triangular triplets. Now, from Theorem 1, it follows that  $F$  aggregates relaxed  $T_i$ -indistinguishability operators into a relaxed  $T$ -indistinguishability operator.  $\square$

### III. CONCLUSIONS

We have addressed the aggregation problem of a collection of relaxed indistinguishability operators where each member of the collection to be merged is a relaxed indistinguishability operator with respect to a different  $t$ -norm. A sufficient condition to merge a collection of the indistinguishability operators under consideration has been given. Moreover, we have characterized those functions that allow to merge a collection of relaxed  $T_i$ -indistinguishability operators into a new with respect to a new  $t$ -norm  $T$ . Namely, the aforesaid characterization is provided in terms of the additive generator of the all involved  $t$ -norms and another functions that transform a  $n$ -dimensional triangular triplet of the positive real line into a 1-dimensional triplet of the positive real line. As future work we will discuss whether some concrete families of aggregation functions (OWA operators, overlap functions, etc) could be used as relaxed  $T$ -indistinguishability operators.

### ACKNOWLEDGEMENTS

This research was funded by the Spanish Ministry of Economy and Competitiveness under Grants DPI2017-86372-C3-3-R, TIN2016-81731-REDT (LODISCO II) and AEI/FEDER,

UE funds, by the Programa Operatiu FEDER 2014-2020 de les Illes Balears, by project ref. PROCOE/4/2017 (Direcció General d' Innovació i Recerca, Govern de les Illes Balears), and by project ROBINS. The latter has received research funding from the EU H2020 framework under GA 779776. This publication reflects only the authors views and the European Union is not liable for any use that may be made of the information contained therein.

### REFERENCES

- [1] B. De Baets and R. Mesiar,  $T$ -partitions, Fuzzy Sets and Syst., 97, (1998), 211–223.
- [2] B. De Baets and R. Mesiar, Pseudo-metrics and  $T$ -equivalences, J. Fuzzy Math., 5 (1997), 471–481.
- [3] B. De Baets and R. Mesiar, Metrics and  $T$ -equalities, J. Math. Anal. Appl., 267 (2002), 531–547.
- [4] G. Beliakov, H. Bustince and T. Calvo-Sánchez, A Practical Guide to Averaging Functions, Springer, Heidelberg, Berlin, New York, 2016.
- [5] G. Beliakov, A. Pradera and T. Calvo, Aggregation Functions: a guide for practitioners, Springer, Heidelberg, Berlin, New York, 2007.
- [6] J. Borsík and J. Doboš, On a product of metric spaces. Math. Slovaca 31 (1981), 193–205.
- [7] B. Bouchon-Meunier, (Ed.), Aggregation and Fusion of Imperfect Information, Studies in Fuzziness and Soft Computing, Vol. 12, Physica-Verlag, Heidelberg, 1998.
- [8] M. Bukatin, R. Kopperman and S.G. Matthews, Some corollaries of the correspondence between partial metric and multivalued equalities, Fuzzy Set. Syst. 256 (2014), 57–72.
- [9] T. Calvo, P. Fuster-Parra and O. Valero, On the problem of relaxed indistinguishability aggregation operators, Proc. of the Workshop on Applied Topological Structures, WATS'17, (2017), 19–26.
- [10] T. Calvo, P. Fuster-Parra and O. Valero, On the Problem of Aggregation of Partial  $T$ -Indistinguishability Operators, Jesús Medina, Manuel Ojeda-Aciego, José Luis Verdegay, David A. Pelta, Inma P. Cabrera, Bernadette Bouchon-Meunier, Ronald R. Yager (Eds.), Proc. Part I. Information Processing and Management of Uncertainty in Knowledge-Based Systems, Theory and Foundations, IPMU'18, (2018), 207–218.
- [11] M. Demicri, The order-theoretic duality and relations between partial metrics and local equalities, Fuzzy Set. Syst. 192 (2011) 45–57.
- [12] M.M. Deza and E. Deza, Encyclopedia of Distances, Springer-Verlag, 2016.
- [13] J. Drewniak and U. Dudziak, Aggregation preserving classes of fuzzy relations, Kybernetika, 41 (3), (2005), 265–284.
- [14] U. Dudziak, Preservation of  $t$ -norm and  $t$ -conorm based properties of fuzzy relations during aggregation process, Proc. 8th Conference of European Society for Fuzzy Logic and Technology, EUSFLAT'2013, (2013), 376–383.
- [15] P. Fuster-Parra, J. Martín, J. J. Miñana and O. Valero, A study on the relationship between relaxed metrics and indistinguishability operators, 2017, (submitted).
- [16] P. Fuster-Parra, J. Martín, J. Recasens and O. Valero, On the metric behavior of partial indistinguishability operators, preprint.
- [17] S. Gottwald, On  $t$ -norms which are related to distances of fuzzy sets, BUSEFAL 50 (1992), 25–30.
- [18] M. Grabisch, J.L. Marichal, R. Mesiar and E. Pap, Aggregation Functions, Cambridge University Press, New York, 2009.
- [19] O. Grigorenko and J. Lebedinska, On another view of aggregation of fuzzy relations, In: S. Galichet, J. Montero and G. Mauris, (eds), Proc. 7th. Conf. EUSFLAT'2011 and LFA'2011, Atlantis Press, (2011), 21–27.
- [20] U. Höhle, Fuzzy equalities and indistinguishability, Proc. of EUFIT'93, Vol. 1, Aachen, 1993 pp. 358–363.
- [21] J. Jacas and J. Recasens, Aggregation of  $T$ -Transitive Relations, Int. J. Intell. Syst. 18 (2003), 1193–1214.
- [22] P. Klement, R. Mesiar and E. Pap, Triangular Norms, Kluwer, Dordrecht, 2000.
- [23] C. M. Ling, Representation of associative function, Publ. Math. Debrecen 12, (1965), 189–212.
- [24] G. Mayor and J. Recasens, Preserving  $T$ -transitivity in: Artificial Intelligence Research and Development, A. Nebot et al. (eds), IOS Press, Vol. 288, 79–87, 2016.



- [25] S. Ovchinnikov, Representation of transitive fuzzy relations, Aspects of Vageness (H. Skala, S. Termini and E. Trillas, eds.), Reidel, Dordrecht, 1984, pp. 105-118.
- [26] S. Ovchinnikov, Similarity relations, fuzzy partitions, and fuzzy orderings, *Fuzzy Sets and Syst.*, 40 (1991), 107-126.
- [27] V. Peneva and I. Popchev, Properties of the aggregation operators related with fuzzy relations, *Fuzzy Sets and Syst.*, 139 (3), (2003), 615-633.
- [28] A. Pradera, E. Trillas, and E. Castiñeira. On distances aggregation, in: Proc. of Information Processing and Management of Uncertainty in Knowledge-Based Systems International Conference, B. Bouchon-Meunier et al. (eds), Universidad Politécnica de Madrid Press, Vol. II, 693-700, 2000.
- [29] A. Pradera, E. Trillas and E. Castiñeira, On the aggregation of some classes of fuzzy relations, in: Technologies for constructing intelligent systems, B. Bouchon-Meunier, J. Gutierrez, L. Magdalena and R. Yager (eds), Springer-Verlag, 125-147, 2002.
- [30] A. Pradera, E. Trillas, A note on pseudo-metrics aggregation, *Int. J. Gen. Syst.* 31 (2002), 41-51.
- [31] J. Recasens, Indistinguishability Operators: Modelling Fuzzy Equalities and Fuzzy Equivalence Relations, Springer, Berlin, 2010.
- [32] E. Trillas, Assaig sobre les relacions d'indistingibilitat, Proc. Primer Congrés Català de Lògica Matemàtica, Barcelona, 1982, pp. 51-59.
- [33] L. Valverde, On the structure of F-indistinguishability operators, *Fuzzy Set. Syst.* 17 (1985) 313-328.
- [34] L. A. Zadeh, Similarity relations and fuzzy orderings, *Inform. Sci.* 3(2), (1971), 177-200.

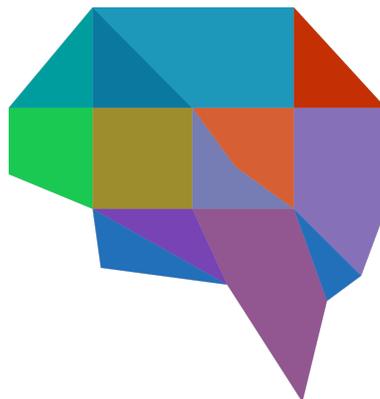


**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 10: SESIÓN ESPECIAL  
NUEVOS ENFOQUES Y  
APLICACIONES EN LA TOMA  
DE DECISIONES EN AMBIENTES  
DE INCERTIDUMBRE II

**Organizadores:**

ROCÍO DE ANDRÉS, TERESA GONZÁLEZ ARTEAGA







# Fuzzy information and contexts for designing Automatic Decision-making Systems\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

M.T. Lamata, D.A. Pelta, J.L. Verdegay  
*Department of Computer Science and Artificial Intelligence*  
*Universidad de Granada*  
Granada, Spain  
{mtl,dpelta,verdegay}@decsai.ugr.es

**Abstract**—The replacement of people by Automatic Decision-making Systems (ADS) has become a threat today. However, it seems that this replacement is unstoppable. Thus, the need for future and current ADS to perform their tasks as perfectly as possible is, more than a necessity an obligation. Hence, the design of these ADS must be carried out in accordance with the theoretical models on which they are to be built. From this point of view, this paper considers the classic definition of General Decision Making Problem and introduces two new key elements for building ADS: the nature of the information available and the context in which the problem is being solved. The new definition allows to cover different models and decision and optimization problems, some of which are presented for illustrative purposes.

**Index Terms**—Fuzzy Information, Decision Making problems, Contexts

# OWA OPERATORS IN THE CALCULATION OF THE AVERAGE GREEN-HOUSE GASES EMISSIONS

**Keivan Amirbagheri**

*Department of Economics and Business, Faculty of Economics and Business, University of Barcelona, Av. Diagonal 690, 08034 Barcelona, Spain*

[kamirbam7@alumnes.ub.edu](mailto:kamirbam7@alumnes.ub.edu)

**José M. Merigó**

*Department of Management Control and Information Systems, School of Economics and Business, University of Chile, Av. Diagonal Paraguay 257, 8330015 Santiago, Chile*

[jmerigo@fen.uchile.cl](mailto:jmerigo@fen.uchile.cl)

## Abstract

This study proposes, through weighted averages and ordered weighted averaging operators, a new aggregation system for the analysis of average gases emissions. We introduce the ordered weighted averaging operators gases emissions, the induced ordered weighted averaging operators gases emissions, the weighted ordered weighted averaging operators gases emissions and the induced probabilistic weighted ordered weighted averaging operators gases emissions. These operators represent a new way of analyzing the average gases emissions of different variables like countries or regions. The work presents further generalizations by using generalized and quasi-arithmetic means. The article also presents an illustrative example regarding the calculations of the average gases emissions in the European region.

**Keywords:** Green-house gases emission, aggregation operators, decision making, ordered weighted average

## 1. Introduction

In the very recent decades, because of an enormous growth of the population and the necessity to provide food for them from one hand and the other hand an immethodical consumption of fossil fuel, our planet is experiencing an unexampled growth in terms of green-house gases (GHG) emission such as CO<sub>2</sub>, CH<sub>4</sub> and N<sub>2</sub>O in its atmosphere that cause an ascending amount of global warming year by year and a drastic climate change [6,20].

There are many works that study the ways that can lead the GHG emission toward the minimization. [19], evaluate the potential influence of vehicle electrification on grid infrastructure and road-traffic

green-house emission. [5] study the impact of electrical power generation on GHG emission in Europe.

Besides, although these works exist but it seems vital to present a comprehensive forecast about the future of countries based on the experts' opinions to provide a clear plan and make a suitable decision to decrease this emission in any of the studied sectors and under various conditions.

Aggregation operators in the related literature with the aim of decision making are diverse and each of them can be used to collect the information [1,2,9-14, 21,23,25]. These techniques give importance to the variables according to certain available subjective or objective findings [17].

A very popular aggregation operator is the weighted average. This aggregation operator is flexible to use in a wide range of problems. Another popular aggregation operator is the ordered weighted average (OWA) [24]. The OWA operator provides a parametrized family of aggregation operators between the minimum and the maximum, weighting the data according to the attitudinal character of the decision-maker. Based on this operator and with the purpose of expanding it, many authors expand and generalize it [3,7,18,22]. There are several types for the concept of expanding and generalizing and the most important item is the form of integrating OWA operator with some key concepts such as, using the induced variables, the probability and the weighted average. [23] propose some new aggregation operators such as the induced ordered weighted geometric averaging (IOWGA) operator, generalized induced ordered weighted averaging (GIOWA) operator, hybrid weighted averaging (HWA) operator.

The purpose of this work is to concentrate on the analysis of the use of the aggregation operators in the calculation of green-house gases (GHG) emission with the aim of developing better decision-making



techniques. To this end, the paper studies several aggregation operators including the WA [1], OWA [24], OWAWA and IOWAWA [11], IOWA [27], POWAWA and IPOWAWA operator [12]. With the use of each operator, a new operator for GHG emission is produced including the OWA GHG emission (OWAGE), induced OWA GHG emission (IOWAGE), ordered weighted averaging-weighted average GHG emission (OWAWAGE), induced OWAWA GHG emission (IOWAWAGE), probabilistic OWAWA GHG emission (POWAWAGE) and induced probabilistic OWAWA GHG emission (IPOWAWAGE).

The work also presents further generalizations by using generalized and quasi-arithmetic means obtaining the generalized OWAGE (GOWAGE). The aim of this approach is to show a more general framework in the analysis of averages by using complex aggregations including with geometric and quadratic averages. The study presents a wide range of particular types of aggregations under this approach.

The work presents an application regarding the calculation of the average gases emissions in Europe. For doing so, the paper considers a multi-expert aggregation problem where four experts analyze the expected average emissions of each European country for the next period. From, the analysis develops several aggregation methods based on the tools developed in the paper including the OWAGE, IOWG and OWAWAGE operators. The main advantage of the OWA operator is the possibility of under or overestimate the information according to the attitudinal character of the decision maker. Thus, depending on the degree of optimism or pessimism of the decision maker, the results may lead to different decisions and interpretations of the information.

## 2. Preliminaries

### 2.1. The weighted average (WA)

The WA [1] is one of the most common aggregation operators found in the literature. It has been used in a wide range of applications. It can be defined as follows.

**Definition 1.** A WA operator of dimension  $n$  is a mapping  $WA: R^n \rightarrow R$  that has an associated weighting vector  $V$ , with  $v_j \in [0,1]$  and  $\sum_{i=1}^n v_i = 1$ , such that:

$$WA(a_1, \dots, a_n) = \sum_{i=1}^n v_i a_i \quad (1)$$

where  $a_i$  represents the argument variable.

### 2.2. The OWA operators

The OWA operator [24] is an aggregation operator that provides a parametrized family of aggregation operators that include the maximum, the minimum and the average criteria as especial cases and can be defined as follows.

**Definition 2.** An OWA operator of dimension  $n$  is a mapping  $OWA: R^n \rightarrow R$  that has an associated weighting vector  $W$  of dimension  $n$  such that sum of the weight is 1 and  $w_j \in [0,1]$ , then:

$$OWA(a_1, a_2, \dots, a_n) = \sum_{j=1}^n w_j b_j \quad (2)$$

where  $b_j$  is the  $j$ th largest of the  $a_i$ .

### 2.3. The Induced OWA operator (IOWA)

The IOWA operator [27] is an extension of the OWA operator. The main difference between OWA and IOWA is that the reordering step is not developed with the values of the arguments  $a_i$ . In this case, the reordering step is carried out with order inducing variables. The IOWA operator also includes as particular cases the maximum, the minimum and the average criteria. It can be defined as follows.

**Definition 3.** An IOWA operator of dimension  $n$  is a mapping  $IOWA: R^n \times R^n \rightarrow R$  that has an associated weighting vector  $W$  of dimension  $n$  with  $\sum_{j=1}^n w_j = 1$  and  $w_j \in [0,1]$ , such that:

$$IOWA(\langle u_1, a_1 \rangle, \langle u_2, a_2 \rangle, \dots, \langle u_n, a_n \rangle) = \sum_{j=1}^n w_j b_j \quad (3)$$

where  $b_j$  is the  $a_i$  value of the IOWA pair  $\langle u_i, a_i \rangle$  having the  $j$ th largest  $u_i$ .  $u_i$  is the order-ranking variable and  $a_i$  is the argument variable.

### 2.4. The probabilistic ordered weighted averaging-weighted average (POWAWA)

The POWAWA [17] operator uses probabilities, weighted average and OWA in the same formulation. It unifies these three concepts by considering the degree of importance that each concept has in the aggregation, depending on the situation considered. The POWAWA operator is defined as follows.

**Definition 4.** A POWAWA operator of dimension  $n$  is a mapping  $POWAWA: R^n \rightarrow R$  that has an associated weighting vector  $W$  of dimension  $n$  with  $w_j \in [0,1]$  and  $\sum_{j=1}^n w_j = 1$  such that:

$$POWAWA(a_1, a_2, \dots, a_n) = \sum_{j=1}^n \hat{v}_j b_j \quad (4)$$

where  $b_j$  is the  $j$ th largest of the  $a_i$ , each argument  $a_i$  has an associated weight  $v_i$  with  $\sum_{i=1}^n v_i = 1$  and  $v_i \in [0,1]$ , a probability  $p_i$  with  $\sum_{i=1}^n p_i = 1$  and  $p_i \in [0,1]$ ,  $\hat{v}_j = C_1 w_j + C_2 v_j + C_3 p_j$ , with  $C_1, C_2$  and  $C_3 \in [0,1]$ ,  $C_1 + C_2 + C_3 = 1$  and  $v_j, p_j$  are the weights  $v_i$  and  $p_i$  ordered according to  $b_j$ , that is to say, according to the  $j$ th largest of the  $a_i$ .

### 2.5. The Induced probabilistic OWAWA operator

The IPOWAWA [12] is an aggregation operator that extends POWAWA operator that uses order-inducing variables that represent complex reordering processes of an aggregation. Thus, it is an aggregation operator that uses induced variables, the probability, the weighted average and the OWA operator. Moreover, it can assess complex reordering processes by using order-inducing variables. Its main advantage is that it provides a more robust formulation than the POWAWA operator because it includes a wide range of cases. It can be defined as follows.

**Definition 5.** The IPOWAWA operator of dimension  $n$  is a mapping  $IPOWAWA: R^n \times R^n \rightarrow R$  that has an associated weighting vector  $W$  of dimension  $n$  with  $w_j \in [0,1]$  and  $\sum_{j=1}^n w_j = 1$ , such that:

$$IPOWAWA(\langle u_1, e_1 \rangle, \langle u_2, e_2 \rangle, \dots, \langle u_n, e_n \rangle) = \sum_{j=1}^n \hat{v}_j b_j \quad (5)$$

where  $b_j$  is the  $a_i$  value of the IPOWAWA pair  $\langle u_i, e_i \rangle$  having the  $j$ th largest  $u_i$ ,  $u_i$  is the order-inducing variable, each argument  $a_i$  has an associated weight  $v_i$  with  $\sum_{i=1}^n v_i = 1$  and  $v_i \in [0,1]$ , a probability  $p_i$  with  $\sum_{i=1}^n p_i = 1$  and  $p_i \in [0,1]$ ,  $\hat{v}_j = C_1 w_j + C_2 v_j + C_3 p_j$ , with  $C_1, C_2$  and  $C_3 \in [0,1]$ ,  $C_1 + C_2 + C_3 = 1$ ,  $v_j$  and  $p_j$  are the weights  $v_i$  and  $p_i$

ordered according to  $b_j$ , that is to say according to the  $j$ th largest of the  $e_i$ .

### 3. Calculation of the average green-house gases (GHG) emission with OWA operators

The purpose of this paper is to calculate the average GHG emission. The average GHG emission represents a numerical value that reports the information of the GHG emission. To calculate this item, using many aggregation operators is possible likewise normal arithmetic mean. These possible aggregation operators could be WA, OWA, IOWA or a combination of them such as OWAWA, IOWAWA, etc. Through using them we prepare some possibilities for the future of GHG emission in different scenarios in a spectrum from the worst case to the best case based on experts' opinions.

The basic operator for analyzing a set of GHG emission is OWAGE. The OWAGE operator is an aggregation operator that analyses an average GHG emission under uncertainty situation. It can be defined as follows for the set of GHG emission  $A = \{e_1, e_2, \dots, e_n\}$ :

$$OWAGE(e_1, e_2, \dots, e_n) = \sum_{j=1}^n w_j f_j \quad (6)$$

where  $f_j$  is the  $j$ th largest of the  $e_i$ .

The other significant aggregation operator is the induced OWA (IOWA) that its reordering step is developed with order including variables. So, by using the IOWA operator we obtain IOWA GHG emission (IOWAGE) that can be defined as follows:

$$IOWAGE(\langle u_1, e_1 \rangle, \langle u_2, e_2 \rangle, \dots, \langle u_n, e_n \rangle) = \sum_{j=1}^n w_j f_j \quad (7)$$

where  $f_j$  is the  $e_i$  value of the IOWA pair  $\langle u_i, e_i \rangle$  having the  $j$ th largest  $u_i$ .  $u_i$  is the order-ranking variable and  $e_i$  is the argument variable.

It is important to mention that this operator is based on considering no extra information. One of the very important aspects of the average GHG emission is the importance of each of them and in other words, their weights in comparison with each other. To this end it is better to use some approaches of information aggregation that combine OWA operators and WA. In the literature there are some aggregation operators with this structure like, the WOWA operator [21], the hybrid average [9] and the OWAWA operators [8]. In this work we apply OWAWA to obtain the OWAWA GHG emission (OWAWAGE) and it is defined as



follows for a set of GHG emission  $A = \{e_1, e_2, \dots, e_n\}$  :

$$OWAWAGE(e_1, e_2, \dots, e_n) = \sum_{j=1}^n \hat{v}_j f_j \tag{8}$$

where  $f_j$  is the  $j$ th largest of the  $e_i$ , each argument  $e_i$  has an associated weight (WA)  $v_i$  with  $\sum_{i=1}^n v_i = 1$  and  $v_i \in [0, 1]$ ,  $\hat{v}_j = \beta w_j + (1 - \beta)v_j$  with  $\beta \in [0, 1]$  and  $v_j$  is the weight (WA)  $v_i$  ordered according to  $b_j$ , that is, according to the  $j$ th largest of the  $e_i$ .

To focus more deeply on our contributions, we implement IOWAWA which is a combination of IOWA operators and WA in the same formulation. By using the IOWAWA operator we obtain IOWAWA GHG emission (IOWAWAGE) that can be defined as follows:

$$IOWAWAGE(\langle u_1, e_1 \rangle, \langle u_2, e_2 \rangle, \dots, \langle u_n, e_n \rangle) = \sum_{j=1}^n \hat{v}_j f_j \tag{9}$$

where  $f_j$  is the  $e_i$  value of the IOWAWA pair  $\langle u_i, e_i \rangle$  having the  $j$ th largest  $u_i$ ,  $u_i$  is the order including variable and  $e_i$  is the argument variable, each argument  $e_i$  has an associated weight (WA)  $v_i$  with  $\sum_{i=1}^n v_i = 1$  and  $v_i \in [0, 1]$ ,  $\hat{v}_j = \beta w_j + (1 - \beta)v_i$  with  $\beta \in [0, 1]$  and  $v_j$  is the weight (WA)  $v_i$  ordered according to  $f_j$ , that is, according to the  $j$ th largest  $u_i$ .

Besides, the other aspect that can be considered and leads results to a better form is probabilities in the attitudinal character of the decision-maker. For this reason, we apply POWAWA operator. By applying the Eq. (7) we could obtain the probabilistic OWAWA GHG emission (POWAWAGE). It can be defined as follows:

$$POWAWAGE(e_1, e_2, \dots, e_n) = \sum_{j=1}^n \hat{v}_j f_j \tag{10}$$

where  $f_j$  is the  $j$ th largest of the  $e_i$ , each argument  $e_i$  has an associated weight  $v_i$  with  $\sum_{i=1}^n v_i = 1$  and  $v_i \in [0, 1]$ , a probability  $p_i$  with  $\sum_{i=1}^n p_i = 1$  and  $p_i \in [0, 1]$ ,  $\hat{v}_j = C_1 w_j + C_2 v_j + C_3 p_j$ , with  $C_1, C_2$  and

$C_3 \in [0, 1]$ ,  $C_1 + C_2 + C_3 = 1$  and  $v_j, p_j$  are the weights  $v_i$  and  $p_i$  ordered according to  $f_j$ , that is to say, according to the  $j$ th largest of the  $e_i$ .

Let us analyze the different families of IOWAWAGE and POWAWAGE in the following paragraphs

First, we are considering the two main cases of the IOWAWAGE operator that are found by analyzing the coefficient  $\beta$ . Basically:

- If  $\beta = 0$ , we get the WA.
- If  $\beta = 1$ , the IOWA operator.
- If  $\beta = 1$  and the ordered position of  $u_i$  is the same than the ordered position of  $f_i$  such that  $f_j$  is the  $j$ th largest of  $e_i$ , the OWA operator.
- Note that when  $\beta$  increases, we are giving more importance to the IOWAGE operator and when  $\beta$  decreases, we give more importance to the WA.

Another group of interesting families are the maximum-WAGE, the minimum-WAGE, the step-IOWAWAGE operator and the usual average.

- The maximum-WAGE is found when  $w_p = 1$  and  $w_j = 0$ , for all  $j \neq p$ , and  $u_p = \text{Max}\{e_i\}$ .
- The minimum-WAGE is formed when  $w_p = 1$  and  $w_j = 0$ , for all  $j \neq p$ , and  $u_p = \text{Min}\{e_i\}$ .

The arithmetic-WAGE is obtained when  $w_j = 1/n$  for all  $j$ , and the weighted average is equal to the OWA when the ordered position of  $i$  is the same as the ordered position of  $j$ . The arithmetic-WAGE (A-WAGE) can be formulated as follows:

$$A\text{-WAGE}(\langle u_1, e_1 \rangle, \langle u_2, e_2 \rangle, \dots, \langle u_n, e_n \rangle) = \frac{1}{n} \beta a_i + (1 - \beta) \sum_{i=1}^n v_i e_i, \tag{11}$$

Note that if  $v_i = 1/n$ , for all  $i$ , then, we get the unification between the arithmetic mean (or simple average) and the IOWAGE operator, that is, the arithmetic-IOWAGE (A-IOWAGE). The A-IOWAGE operator can be formulated as follows:

$$A\text{-IOWAGE}(\langle u_1, e_1 \rangle, \langle u_2, e_2 \rangle, \dots, \langle u_n, e_n \rangle) = \beta \sum_{j=1}^n w_j b_j + (1 - \beta) \frac{1}{n} e_i. \tag{12}$$

Following the OWA literature [13, 25, 27], we can develop many other families of IOWAWA operators such as:

- The olympic-IOWAWAGE operator ( $w_1 = w_n = 0$ , and  $w_j = 1/(n - 2)$  for all others).

- The general olympic-IOWAWAGE operator ( $w_j = 0$  for  $j = 1, 2, \dots, k, n, n-1, \dots, n-k+1$ ; and for all others  $w_{j^*} = 1/(n-2k)$ , where  $k < n/2$ ).
- The centered-IOWAWAGE (if it is symmetric, strongly decaying from the center to the maximum and the minimum, and inclusive).

Many other particular cases can be studied by looking at different expressions of the weighting vectors and the coefficients  $C_1, C_2$  and  $C_3$ . For example:

- If  $C_1 = 1$ , we obtain the OWAGE operator.
- If  $C_2 = 1$ , the weighted GHG emission (WGE).
- If  $C_3 = 1$ , the probabilistic GHG emission (PGE).
- If  $C_1 = 0$ , the probabilistic weighted averaging GHG emission (PWAGE).
- If  $C_2 = 0$ , the probabilistic OWA GHG emission (POWAGE).
- If  $C_3 = 0$ , the OWAWA GHG emission (OWAWAGE) [14].

#### 4. Generalizations with generalized and quasi-arithmetic means

Generalization of the OWA operators is possible to do by generalized and quasi-arithmetic averaging aggregation operators that as the most common one generalized OWA (GOWA) [26] and then quasi-arithmetic OWA (Quasi-OWA) [4] are formed. These functions apply a general framework including particular cases. The GOWA operator applied to the analysis of gases emissions is called GOWA gases emissions (GOWAGE) and is defined as follows.

**Definition 6.** A GOWAGE operator of dimension  $n$  is a mapping  $GOWA: R^n \rightarrow R$  that has an associated weighting vector  $W$  of dimension  $n$  with  $\sum_{j=1}^n w_j = 1$  and  $w_j \in [0, 1]$ , such that:

$$GOWAGE(e_1, e_2, \dots, e_n) = \left( \sum_{j=1}^n w_j b_j^\lambda \right)^{1/\lambda} \quad (13)$$

where  $b_j$  is the  $j$ th largest of the  $e_i$ , and  $\lambda$  is a parameter such that  $\lambda \in (-\infty, \infty) - \{0\}$ .

Like the section 3, this operator also has the particular cases of the maximum, the minimum and the generalized mean (GM). Besides, there are some

special cases that can be obtained by maneuvering on the values of  $\lambda$ , such as:

- If  $\lambda = 1$ , the usual OWAGE operator.
- If  $\lambda \rightarrow 0$ , the ordered weighted geometric average gases emissions (OWGAGE).
- If  $\lambda = 2$ , the ordered weighted quadratic average gases emissions (OWQAGE).

Quasi-arithmetic OWA gases emissions (Quasi-OWAGE) operator is the other generalization that uses the quasi-arithmetic means instead of the generalized means. So, it replaces the parameter  $\lambda$  by a strictly continuous monotonic function  $g$ .

**Definition 7.** A Quasi-OWAGE operator of dimension  $n$  is a mapping Quasi-OWAGE:  $R^n \rightarrow R$  that has an associated weighting vector  $W$  of dimension  $n$  with  $\sum_{j=1}^n w_j = 1$  and  $w_j \in [0, 1]$ , then:

$$Quasi-OWAGE(e_1, e_2, \dots, e_n) = g^{-1} \left( \sum_{j=1}^n w_j g(b_{(j)}) \right) \quad (14)$$

where  $b_j$  is the  $j$ th largest of the  $e_i$  and  $g$  is a strictly continuous monotonic function.

#### 5. Conclusions

The purpose of this study is to concentrate on the analysis of the use of the aggregation operators in the calculation of GHG emission with the aim of developing better decision-making techniques. In this study we reviewed some of the important operators of the family of OWA. This review started with simple WA and continued with OWA operator. Moreover, we also analyzed some operators that form by combination of two or more aggregation operators. So, these operators are, IOWAGE, OWAWAGE, IOWAWAGE, POWAWAGE and IPOWAWAGE.

In addition, through these formulations, we found some particular cases in either IOWAWAGE or POWAWAGE operators such as, olympic-IOWAWAGE, S-IOWAWAGE, centered-IOWAWAGE, maximum, minimum and arithmetic probabilistic weighted average, and arithmetic probabilistic ordered weighted average. Furthermore, some other generalizations are developed by using generalized and quasi-arithmetic means obtaining the GOWAGE and the Quasi-OWAGE operators.

The study provides a simple example to review the function of two simple aggregations operators of average green-house gases emission. During this example we review weighted average gases emission (WAGE) and ordered weighted average gases emission (OWAGE) to represent the difference between the result of the calculation based on these operators.



## References

- [1] G. Beliakov, A. Pradera and T. Calvo, *Aggregation Functions: A Guide for Practitioners*. Berlin: Springer-Verlag, 2007.
- [2] T. Calvo, G. Mayor and R. Mesiar, *Aggregation Operators: New Trends and Applications*. New York: Physica-Verlag, 2012.
- [3] A. Emrouznejad and M. Marra, Ordered weighted averaging operators 1988–2014: A citation-based literature survey. *International Journal of Intelligent Systems*, 29:994-1014, 2014.
- [4] J. Fodor, J.L. Marichal and M. Roubens, Characterization of the ordered weighted averaging operators. *IEEE Transactions on Fuzzy Systems*, 3:236-240, 1995.
- [5] T.J. Hammons, Impact of electric power generation on green house gas emissions in Europe: Russia, Greece, Italy and views of the EU Power Plant Supply Industry—a critical analysis. *International Journal of Electrical Power & Energy Systems*, 28:548-564, 2006.
- [6] A.F. Hastings, M. Wattenbach, w. Eugster, C. Li, N. Buchmann and P. Smith, P. Uncertainty propagation in soil greenhouse gas emission models: an experiment using the DNDC model and at the Oensingen cropland site. *Agriculture, Ecosystems & Environment*, 136:97-110, 2010.
- [7] J. Kacprzyk and S. Zadrozny, Towards a general and unified characterization of individual and collective choice functions under fuzzy and nonfuzzy preferences and majority via the ordered weighted average operators. *International Journal of Intelligent Systems*, 24:4-26, 2009.
- [8] J.M. Merigó, A unified model between the weighted average and the induced OWA operators. *Expert Systems with Applications*, 38:11560-11572, 2011.
- [9] J.M. Merigó, M. Casanovas, Fuzzy generalized hybrid aggregation operators and its application in decision making. *International Journal of Fuzzy Systems*, 12:15-24, 2010a.
- [10] J.M. Merigó, M. Casanovas, The fuzzy generalized OWA operator and its application in strategic decision making. *Cybernetics and Systems*, 41:359-370, 2010b.
- [11] J.M. Merigó and A.M. Gil-Lafuente, The induced generalized OWA operator. *Information Sciences*, 179:729-741, 2009.
- [12] J.M. Merigó, C. Lobato-Carral, A. Carrilero-Castillo, Decision making in European Union under risk and uncertainty, *European Journal of International Management*, 6:590-609, 2012.
- [13] J.M. Merigó, D. Palacios-Marqués, M.M. Benavides-Espinosa, Aggregation methods to calculate the average price. *Journal of Business Research*, 68: 1574-1580, 2015.
- [14] J.M. Merigó, D. Palacios-Marqués, P. Soto-Acosta, Distance measures, weighted averages, OWA operators and Bonferroni means. *Applied Soft Computing*, 50:356-366, 2017.
- [15] J.M. Merigó, M. Peris-Ortíz, A. Navarro-García, C. Rueda-Armengot. Aggregation operators in economic growth analysis and entrepreneurial group decision-making, *Applied Soft Computing*, 47:141-150, 2016.
- [16] J.M. Merigó, J.B. Yang, D.L. Xu, Demand analysis with aggregation systems. *International Journal of Intelligent Systems*, 31:425-443, 2016.
- [17] J.M. Merigó, L. Zhou, D. Yu, N. Alrajeh and K. Alnowibet, Probabilistic OWA distances applied to asset management. *Soft Computing*, 1-24, 2018.
- [18] R. Mesiar A. Stupňanová, and R.R. Yager, Generalizations of OWA operators. *IEEE Transactions on Fuzzy Systems*, 23:2154-2162, 2015.
- [19] M. Sorrentino, G. Rizzo and L. Sorrentino, A study aimed at assessing the potential impact of vehicle electrification on grid infrastructure and road-traffic green house emissions. *Applied Energy*, 120:31-40, 2014.
- [20] C.E. Stewart, J. Zheng, J. Botte and M.F. Cotrufo, Co-generated fast pyrolysis biochar mitigates green-house gas emissions and increases carbon sequestration in temperate soils. *GCB Bioenergy*, 5:153-164, 2013.
- [21] V. Torra, The weighted OWA operator. *International Journal of Intelligent Systems*, 12:153-166, 1997.
- [22] V. Torra and Y. Narukawa, Some relationships between Losonczy's based OWA generalizations and the Choquet–Stieltjes integral. *Soft Computing*, 14: 465-472, 2010.
- [23] Z.S. Xu, Q.L. Da, An overview of operators for aggregating information. *International Journal of Intelligent Systems*, 18:953-969, 2003.
- [24] R.R. Yager, On ordered weighted averaging aggregation operators in multi-criteria decision making. *IEEE Transactions on Systems, Man and Cybernetics B*, 18:183-190, 1988.
- [25] R.R. Yager, Families of OWA operators. *Fuzzy Sets and Systems*, 59: 125-148, 1993.
- [26] R.R. Yager, Generalized OWA aggregation operators. *Fuzzy Optimization and Decision Making*, 3:93-107, 2004.
- [27] R.R. Yager and D.P. Filev, Induced ordered weighted averaging operators. *IEEE Transactions on Systems, Man and Cybernetics B*, 29:141-150, 1999.

# Fuzzy linguistic ranking model for Web Accessibility Test tools

Noe Zermeño\*, Lucas D.D.R. Calache†, Rosana Montes\* and Francisco Herrera\*

\*Andalusian Research Institute on Data Science and Computational Intelligence, DaSCI

University of Granada, Granada, Spain

Emails: nzermeno@correo.ugr.es, rosana@ugr.es, herrera@decsai.ugr.es

†São Carlos School of Engineering, University of São Paulo, Brazil

Email: lucascalache@usp.br

**Abstract**—There are dozens of tools to automatically evaluate web accessibility. Some are online, and some are toolbars to complement web browsers. In order to select the best Web Accessibility Test Tool, various aspects should be considered. Among the various aspects, the evaluation environment has an important role to assume in the evaluation criteria of the website. The ability to evaluate websites that require user permissions or they are freely accessible could affect the accessibility outcome due to limited or no access to the tool. In addition, the interpretability of the results differs from one tool to another, and it can be difficult to identify the areas of opportunity for improvement of the website evaluated. To select the best tool that matches experts' needs, it is important to have a group of experts in the area. These experts will give their opinions on the criteria according to which the tools will be evaluated. Each Web Accessibility Test Tool is an alternative in a decision making problem (DM). A DM which is evaluated by a group of experts is called a Multi-Expert Multi-Criteria (MEMC). Contrary to studies where the assessments are quantitative, this research uses Computing with Words (CW) processes. Because experts may have uncertainty at the time of issuing their evaluation, Intuitionistic Fuzzy Sets (IFS) are used to work with that uncertainty. Finally, a ranking of the evaluated tools is carried out by TOPSIS.

**Keywords**—Intuitionistic Fuzzy Set (IFS), TOPSIS, Multi-Expert Multi-Criteria Linguistic Decision Making (MEM-CLDM), Web Accessibility Tools Test, Ranking.

## I. INTRODUCTION

The World Wide Web Consortium (W3C) is an international community working towards international standards for the web. W3C dictates a series of standards –WCAG 1.0<sup>1</sup> in 1999 and WCAG 2.0<sup>2</sup> in 2008– to make web information accessible to everyone regardless of hardware, software, network infrastructure, language, culture, geographic location, or physical or mental ability. Currently there are several tools that evaluate the accessibility of websites automatically. The tools contain different features that may or may not facilitate the evaluation of the site depending on the context in which are applied. Choosing the right tool for the expert's needs is a decision making problem (DM). A DM is a typical problem that has different alternatives to choose from valued by experts in the topic.

In this document, a fuzzy linguistic model is proposed for evaluating accessibility tools through nine criteria: (1)

Learnability, (2) Scope of application, (3) Displays element evaluation, (4) Accessibility level, (5) Accuracy, (6) CSS evaluation, (7) Reports, (8) Intuitivity, (9) Standardized output. Commonly, the valuation process is done using numerical scales. This research makes use of enhanced linguistic terms in order to take advantage of the knowledge and experience of the experts in a better way, since the evaluation is performed using natural language. The decision-making process is carried out by intuitionist linguistic representation using linguistic sets in the expert opinions on the criteria to be evaluated of the accessibility tools. Finally, using TOPSIS, the results are aggregated to rank the tools evaluated.

This document is structured as follows: Section II provides a descriptive summary of the preliminaries relating to the Intuitionist linguistic model as well as TOPSIS as a technique for the ranking of alternatives. In Section III, we present a Fuzzy linguistic ranking model. In Section IV, we apply a ranking model for Web Accessibility Test tools. Finally, in Section V, the conclusions are presented.

## II. PRELIMINARIES

This section describes the methodologies applied to the Multi-Expert Multi-Criteria Linguistic Decision Making (MEMCLDM) problem for ranking in the alternative selection.

### A. Multi Criteria Decision Making

The Multi-Criteria Decision Making (MCDM) was introduced in the early 1970s. It is a tool used for problem assessment and decision making with multiple alternatives that are evaluated considering multiple criteria [1], [2].

MCDM often deal with different types of problems such as selection, ranking and classification problems. The aim on each kind of problem is different: (1) selection problems is expected to find the best alternative; (2) the ranking problems are aimed at determining the suitability of all alternatives, which is presented as a hierarchy from the best to the worst and (3) in the classification problems we want to know which alternatives belong to which class of a predefined set of ordered classes.

There are several methods of solving MCDM problems that are used to form a ranking of alternatives. The TOPSIS method [3] is one of them. TOPSIS is based on an aggregation function

<sup>1</sup><https://www.w3.org/TR/WAI-WEBCONTENT/>

<sup>2</sup><https://www.w3.org/TR/WCAG20/>



of the experts' evaluation scores and determines the best alternative by calculating the distances between the positive and negative ideal solution.

MCDM problems can be evaluated by various experts to be approached as MEMCLDM problems. These experts are usually people with experience in the subject to be assessed. Alternatives can be assessed quantitatively or qualitatively. To evaluate qualitative information, the use of the Fuzzy Set Theory (FST) [4], proposed by Zadeh in 1965, has been very successful. In order to achieve an efficient evaluation of the perception of the experts, the use of linguistic variables[5] and the procedures of Computation with Words (CW) [6], [7] are used in intelligent computer systems [8], [9], [10], [11].

**B. Intuitionistic fuzzy representation model**

Intuitionistic Fuzzy Set (IFS) was proposed by Atanassov in 1986. IFS [12] is characterized by having simultaneously a membership and a non-membership with a degree of hesitance. The IFS are models of information representation used to support decision making and are very useful because of the ability to express imprecise or uncertain information more flexibly than the traditional fuzzy sets [2], [13].

According to Atanassov [12] an IFS  $A$ , in the universe  $X = \{x_1, x_2, \dots, x_n\}$ , it is represented as:

$$\tilde{A} = \langle x_j, \mu_{\tilde{A}}(x_j), \nu_{\tilde{A}}(x_j) \mid x_j \in X \rangle$$

where  $\mu_{\tilde{A}}(x_j) \in [0, 1]$  and  $\nu_{\tilde{A}}(x_j) \in [0, 1]$  represents respectively the membership and the non-membership degrees of the element  $x_j$ . Then an IFS has the following requirement:

$$0 \leq \mu_{\tilde{A}}(x_j) + \nu_{\tilde{A}}(x_j) \leq 1$$

The function  $\pi_{\tilde{A}}(x_j)$  represents the degree of hesitancy of  $x_j$  and it is defined as:

$$\pi_{\tilde{A}}(x_j) = 1 - \mu_{\tilde{A}}(x_j) - \nu_{\tilde{A}}(x_j)$$

Let  $\alpha$  and  $\beta$  be two intuitionistic fuzzy sets,  $\lambda$  be a number. Hence, the main algebraic operations of any two intuitionistic fuzzy sets  $\alpha = (\mu_{\alpha}, \nu_{\alpha})$  and  $\beta = (\mu_{\beta}, \nu_{\beta})$  can be defined in the following way [14] and [15]:

1) *Addition*  $\oplus$ :

$$\alpha \oplus \beta = (\mu_{\alpha} + \mu_{\beta} - \mu_{\alpha}\mu_{\beta}, \nu_{\alpha}\nu_{\beta}); \quad (1)$$

2) *Product*  $\otimes$ :

$$\alpha \otimes \beta = (\mu_{\alpha}\mu_{\beta}, \nu_{\alpha} + \nu_{\beta} - \nu_{\alpha}\nu_{\beta}); \quad (2)$$

3) *Scalar product*:

$$\lambda\alpha = (1 - (1 - \mu_{\alpha})^{\lambda}, \nu_{\alpha}^{\lambda}), \lambda > 0; \quad (3)$$

4) *Scalar power*:

$$\alpha^{\lambda} = (\mu_{\alpha}^{\lambda}, 1 - (1 - \nu_{\alpha})^{\lambda}), \lambda > 0. \quad (4)$$

The Intuitionistic Fuzzy Weighted Average (IFWA) aggregation operator was initially proposed by [15], it has been

used to aggregate the individual opinions of decision makers [16], [17]. Let  $R^{(k)} = (r_{ij}^{(k)})_{m \times n}$  be an intuitionist decision-making matrix with the evaluations of each alternative  $A_i$  with  $(i = 1, \dots, m)$  and criterion  $C_j$  with  $(j = 1, \dots, n)$  by each decision maker  $DM_k$  with  $(k = 1, \dots, d)$ . Let  $w_k$  be the weight of each decision maker  $DM_k$  where  $\sum_{k=1}^d w_k = 1$ . Then the final result of applying the IFWA aggregation operator is an IFS value given by Eq.(5):

$$\begin{aligned} IFWA_w &= IFWA_w(r_{ij}^{(1)}, r_{ij}^{(2)}, \dots, r_{ij}^{(d)}) \\ &= w_1 r_{ij}^{(1)} \oplus w_2 r_{ij}^{(2)} \oplus w_3 r_{ij}^{(3)} \oplus \dots \oplus w_k r_{ij}^{(d)} \\ &= [\chi, \psi, \delta] \end{aligned} \quad (5)$$

where

$$\begin{aligned} \chi &= 1 - \prod_{k=1}^d (1 - \mu_{ij}^{(k)})^{w_k} \\ \psi &= \prod_{k=1}^d (\nu_{ij}^{(k)})^{w_k} \\ \delta &= \prod_{k=1}^d (1 - \mu_{ij}^{(k)})^{w_k} - \prod_{k=1}^d (\nu_{ij}^{(k)})^{w_k}. \end{aligned}$$

Intuitionistic fuzzy representation has been widely used with multicriteria decision-making techniques [18] such as Intuitionistic fuzzy TOPSIS [17], Intuitionistic fuzzy AHP [19], Intuitionistic fuzzy VIKOR [20], Intuitionistic fuzzy ELECTRE [21], among others, with the purpose of order the alternatives.

**C. Intuitionistic fuzzy TOPSIS**

There are different techniques for the ranking of alternatives in MEMCLDM. TOPSIS is a technique which uses the order by similarity with an ideal solution [3]. TOPSIS is based on the fact that the alternative selected must be the one that contains the closest distance from the ideal solution and the furthest distance from the negative solution. The Fuzzy TOPSIS technique is widely applied in decision making [22] and it is considered as one of the best MCDM methods to solve problems. Due to its simplicity of application avoiding it application in alternatives ranking when a new alternative is inserted [23]. Boran et al. [16] proposes the Intuitionistic fuzzy TOPSIS to be applied following these steps:

1) Let  $W_j = (\mu_j, \nu_j)$  be the intuitionistic fuzzy weight of each criteria  $C_j$  according to alternative  $A_i$ . Let  $R' = (r'_{ij})_{m \times n}$  be the matrix of the aggregated intuitionistic fuzz sets with  $m$  alternatives and  $n$  criteria. Then the weighted normalized matrix is calculated by Eq.(6) and Eq.(7).

$$R' \otimes W_j = \{(\mu_{r'_{ij}} \mu_{W_j}, \nu_{r'_{ij}} + \nu_{W_j} - \nu_{r'_{ij}} \nu_{W_j}) \mid r'_{ij} \in R'\} \quad (6)$$

$$\pi_{r'_{ij}} = (1 - \nu_{r'_{ij}} - \nu_{W_j} - \mu_{r'_{ij}} \mu_{W_j} + \nu_{r'_{ij}} \nu_{W_j}) \quad (7)$$

2) The positive intuitionistic fuzzy ideal solution vector  $A^+$  can be determined as:

$$A^+ = (\mu_{A^-} W_j, \nu_{A^+} W_j) \quad (8)$$

where

$$\begin{aligned}\mu_{A^+}W_j &= \max_i \mu_{r'_{ij}} W_j \\ \nu_{A^+}W_j &= \min_i \nu_{r'_{ij}} W_j.\end{aligned}$$

- 3) The negative intuitionistic fuzzy ideal solution vector  $A^-$  can be determined as:

$$A^- = (\mu_{A^-}W_j, \nu_{A^-}W_j) \quad (9)$$

where

$$\begin{aligned}\mu_{A^-}W_j &= \min_i \mu_{r'_{ij}} W_j \\ \nu_{A^-}W_j &= \max_i \nu_{r'_{ij}} W_j.\end{aligned}$$

- 4) Calculate the distance measurement, using the Euclidean distance. The separation of each alternative from the ideal solution is given as:

$$S_i^+ = \sqrt{\frac{1}{2n} \sum_{j=1}^n [(\mu_{r'_{ij}}W_j - \mu_{A^+}W_j)^2 + (\nu_{r'_{ij}}W_j - \nu_{A^+}W_j)^2 + (\pi_{r'_{ij}}W_j - \pi_{A^+}W_j)^2]}. \quad (10)$$

- 5) Similarly, the separation of the negative solution is given as:

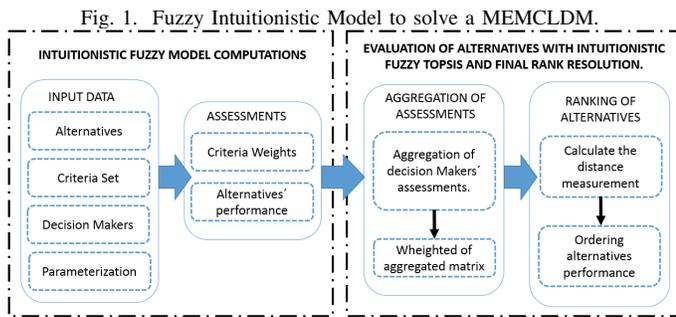
$$S_i^- = \sqrt{\frac{1}{2n} \sum_{j=1}^n [(\mu_{r'_{ij}}W_j - \mu_{A^-}W_j)^2 + (\nu_{r'_{ij}}W_j - \nu_{A^-}W_j)^2 + (\pi_{r'_{ij}}W_j - \pi_{A^-}W_j)^2]}. \quad (11)$$

- 6) Then rank the order of preference by the relative proximity coefficient as:

$$RPA_i = \frac{S_i^-}{S_i^- + S_i^+}. \quad (12)$$

### III. A FUZZY LINGUISTIC RANKING MODEL

The proposed model for the ranking problem of the list of tools for evaluating Web Accessibility Test tools consists of three basic stages: (1) Representation phase, (2) Aggregation phase and (3) Exploitation phase. Figure (1) presents the proposed phases:



#### A. Representation phase

The first phase consist of the definition of Linguistic Terms Set (LTS) that will be used for decision making. Decision makers denoted as  $DM_k$  with  $(k = 1, \dots, d)$ . Should be select a set of diverse  $DM$  that have experience and knowledge directly related to the problem to evaluate the available alternatives. The set of alternatives  $A_i$  with  $(i = 1, \dots, m)$  are evaluated using a set of criteria  $C_j$  with  $(j = 1, \dots, n)$ .

The weight  $W_j$  of each criterion  $C_j$  assigned by a coordinator using an Intuitionistic Fuzzy Linguistic Set (IFLS). It would be desirable to represent the input linguistic information with a representation able to express uncertainty and subjectivity in judgments.

#### B. Aggregation phase

The second phase consists of aggregating the decision makers judgments. The IFWA operator presented in Eq. (5) can be used to aggregate them into a matrix of group decision making  $R' = (r'_{ij})_{m \times n}$ , where  $m$  and  $n$  denotes the number of evaluated alternatives and criteria respectively. Next, a weighting process of the group decision making matrix  $R'$  is performed using the weight vector  $W_j$  and applying Eq. (6) and Eq. (7).

#### C. Exploitation phase

In the last step of the decision-making process, the performance of each alternative should be calculated using the distance measurement. The ideal intuitionistic fuzzy positive and negative solutions are obtained as Eq. (8) and Eq. (9). The distance between each aggregated weighted evaluation of alternatives' performances and the ideal intuitionistic fuzzy positive and negative solution is calculated by Eq. (10) and Eq. (11). The final score of the alternatives performance is calculated by relative proximity as in Eq. (12). Finally, the alternatives are ordered.

### IV. A RANKING MODEL FOR WEB ACCESSIBILITY TEST TOOLS

It is desired to evaluate the level of accessibility of a web system. There are several tools supported by the World Wide Web Consortium (W3C) with different features. The  $DM$  set limits the main set to the six tools commonly used among them. The set of Web Accessibility Test (WAT) tools are evaluated in relation to a set of nine criteria. It must be decided which of this set of six tools is best suited to your needs. The tools considered are the following:

- 1) Wave<sup>3</sup> ( $c_1$ ),
- 2) Achecher<sup>4</sup> ( $c_2$ ),
- 3) eXaminator<sup>5</sup> ( $c_3$ ),
- 4) AccessMonitor<sup>6</sup> ( $c_4$ ),
- 5) Accessibility Check<sup>7</sup> ( $c_5$ ),
- 6) TAW<sup>8</sup> ( $c_6$ ).

#### A. Representation phase

For this case-study there are  $d = 7$  decision makers who have knowledge in web development. The set of  $m = 6$  WAT tools are assessed according to a set of  $n = 9$  criteria described in Table (I). The linguistic intuitionistic variables in

<sup>3</sup><http://wave.webaim.org/>

<sup>4</sup><https://achecker.ca/checker/index.php>

<sup>5</sup><http://examinator.ws/>

<sup>6</sup><http://www.acessibilidade.gov.pt/accessmonitor/>

<sup>7</sup><http://www.etre.com/tools/accessibilitycheck/>

<sup>8</sup><https://www.tawdis.net/>



TABLE I

DESCRIPTION OF THE CRITERIA USED TO EVALUATE WEB ACCESSIBILITY TOOLS.

Criteria for evaluating accessibility assessment tools.		
Criteria $C_j$	Definition	
$c_1$	Learnability	Enables simple and efficient learning.
$c_2$	Scope of application	Allows evaluation on sites with user permissions from an external site.
$c_3$	Displays element evaluation	Reveals the evaluations of each element to resolve any errors efficiently.
$c_4$	Accessibility level	Calculates the overall level of accessibility (A, AA, AAA).
$c_5$	Accuracy	Describes the assessments: (1) failed, 2 (warning) and (3) passed in a similar form as a manual assessment.
$c_6$	CSS evaluation	Evaluates accessibility of CSS content.
$c_7$	Reports	Generates reports that are easily interpreted by experts as ordinary users.
$c_8$	Intuitivity	Indicates inspected items for easy identification of errors, warnings and approvals.
$c_9$	Standardized output	Provides a report in standardized format: XML, JSON and YAML.

TABLE II

LINGUISTIC VARIABLES FOR THE IMPORTANCE WEIGHT OF EACH CRITERIA EXPRESSED AS IFS

Label	Short	$\mu$	$\nu$
Very High	VH	0.90	0.05
High	H	0.75	0.20
Medium	M	0.50	0.45
Low	L	0.35	0.60
Very Low	VL	0.10	0.90

Table (II) were used by a coordinator to define the weight  $W_j$  of each criteria  $C_j$ , as presented in Table (III). Also, using Table (II), each  $DM_k$  evaluates the performance of each alternative in each criterion. Table (IV) presents decision makers assessments.

B. Aggregation phase

Once the individual matrix of intuitionistic evaluations has been obtained, the matrix must be aggregated using the IFWA operator presented in Eq. (5). In this study-case, the weight of the decision makers were considered the same. The IFWA operator is used to aggregate them into a group decision making matrix. The aggregation results are presented in Table (V). Due to the space, only two assessments are displayed. Next, a weighting process of the group decision matrix  $R'$  is performed using the weight vector  $W_j$  and applying the Eq. (6) and Eq. (7). The results of the weighted aggregation for the criteria  $c_1$  and  $c_2$  are displayed in Table (VI).

TABLE III

INTUITIONISTIC FUZZY NUMBER (IFN) FOR EACH LINGUISTIC LABEL IN EACH CRITERIA

Intuitionistic Fuzzy Sets				
$C_j$	Criteria	Assessment	$\mu$	$\nu$
$c_1$	Learnability	Very High	0.90	0.05
$c_2$	Scope of application	Very High	0.90	0.05
$c_3$	Displays element evaluation	High	0.75	0.20
$c_4$	Accessibility level	Medium	0.50	0.45
$c_5$	Accuracy	High	0.75	0.20
$c_6$	Css evaluation	Medium	0.50	0.45
$c_7$	Reports	High	0.75	0.20
$c_8$	Intuition	High	0.75	0.20
$c_9$	Standardized output	Very High	0.90	0.05

C. Exploitation phase

In this step, the performance of each alternative should be calculated using the distance measurement from Fuzzy TOPSIS technique. The intuitionistic fuzzy ideal positive and negative solution are founded using Eq. (8) and Eq. (9). The distance between each aggregate weighted evaluation of the alternatives' results and the intuitionistic fuzzy ideal positive and negative solution is calculated using the Eq. (10) and Eq. (11). The results are presented by Table (VIII) and Table (IX) respectively.

Finally, the alternatives are ordered by relative proximity as in Eq. (12). The resulting order is presented in Table (X) with  $a_1 > a_2 > a_6 > a_5 > a_3 > a_4$ . Alternative  $a_1$  is selected as the best tool with the best scores in 6 of 9 criteria evaluated. The selected tool can be highlight as very intuitive, since it marks errors and warnings in the html label, due this, it is easy to identify where are the errors.

V. CONCLUSION

This study proposed and tested a Multi-Expert Multi-Criteria Decision model in order to evaluate and select Web Accessibility Test tools that combines the Intuitionistic fuzzy representation and the TOPSIS technique. It fulfills several important characteristics for a decision making process:

- The use of linguistic variables instead of numerical scales enhances the assessment of alternatives in decision-making problems because the cognitive processes of human beings accept words rather than numbers;
- The use of Intuitionistic Fuzzy Set (ISF) is used due to the imprecision found in the parameterization since there may be a degree of hesitation. IFS takes into account the degree of membership, degree of non-membership and hesitancy;
- Finally, being able to rank the alternatives with fuzzy information allows a better interpretability of results for decision makers.

The Wave tool resulted best valued in comparison with five tools. Wave is considered an easy learning tool, the plug-in installation to the browser is very simple. Wave has a high degree of intuitiveness and as a toolbar, it allows the evaluation of websites with the users' permissions. The assessment is displayed on each element evaluated, enabling rapid identification of errors and warnings. Experts rank the Wave tool first, considering the set of criteria. As a further research, it is suggested to explore other techniques in combination with linguistic fuzzy representations and compare their results with the proposal presented in this study.

ACKNOWLEDGMENT

This work was partly supported by the research project TIN2017-89517-P of the Ministry of Economy.

REFERENCES

[1] S. Pohekar and M. Ramachandran, "Application of multi-criteria decision making to sustainable energy planning—a review," *Renewable and Sustainable Energy Reviews*, vol. 8, no. 4, pp. 365–381, 2004.



TABLE IV  
VALUATIONS OF  $d = 7$  DECISION MAKERS FOR  $m = 6$  ALTERNATIVES ACCORDING TO  $n = 9$  CRITERIA

Criteria	Alternatives	$dm_1$			$dm_2$			$dm_3$			$dm_4$			$dm_5$			$dm_6$			$dm_7$		
		Linguistic label	$\mu$	$\nu$																		
$c_1$	$a_1$	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20
	$a_2$	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	VH	0.90	0.05	L	0.35	0.60	H	0.75	0.20
	$a_3$	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45
	$a_4$	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	L	0.35	0.60									
	$a_5$	L	0.35	0.60	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45	L	0.35	0.60
	$a_6$	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20
$c_2$	$a_1$	VH	0.90	0.05	VH	0.90	0.05	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	VH	0.90	0.05
	$a_2$	H	0.75	0.20	VL	0.10	0.90	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45	M	0.50	0.45	VL	0.10	0.90
	$a_3$	H	0.75	0.20	VH	0.90	0.05	M	0.50	0.45	M	0.50	0.45	H	0.75	0.20	VL	0.10	0.90	H	0.75	0.20
	$a_4$	H	0.75	0.20	L	0.35	0.60	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20	H	0.75	0.20	VL	0.10	0.90
	$a_5$	M	0.50	0.45	H	0.75	0.20	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45
	$a_6$	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	H	0.75	0.20
$c_3$	$a_1$	H	0.75	0.20	VH	0.90	0.05	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20	VH	0.90	0.05
	$a_2$	VH	0.90	0.05	M	0.50	0.45	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	M	0.50	0.45	H	0.75	0.20
	$a_3$	H	0.75	0.20	VL	0.10	0.90	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45	M	0.50	0.45
	$a_4$	L	0.35	0.60	VL	0.10	0.90	H	0.75	0.20	L	0.35	0.60	L	0.35	0.60	L	0.35	0.60	VL	0.10	0.90
	$a_5$	M	0.50	0.45	VL	0.10	0.90	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	VL	0.10	0.90	M	0.50	0.45
	$a_6$	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45												
$c_4$	$a_1$	H	0.75	0.20	VL	0.10	0.90	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	L	0.35	0.60	M	0.50	0.45
	$a_2$	H	0.75	0.20	H	0.75	0.20	VL	0.10	0.90	VH	0.90	0.05	H	0.75	0.20	VH	0.90	0.05	VL	0.10	0.90
	$a_3$	H	0.75	0.20	H	0.75	0.20	VL	0.10	0.90	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20
	$a_4$	L	0.35	0.60	VL	0.10	0.90															
	$a_5$	VL	0.10	0.90	VH	0.90	0.05	VL	0.10	0.90	VH	0.90	0.05	VH	0.90	0.05	VH	0.90	0.05	VL	0.10	0.90
	$a_6$	VH	0.90	0.05	H	0.75	0.20	VL	0.10	0.90	VH	0.90	0.05	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20
$c_5$	$a_1$	H	0.75	0.20	VH	0.90	0.05	M	0.50	0.45	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20
	$a_2$	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45									
	$a_3$	H	0.75	0.20	VL	0.10	0.90	H	0.75	0.20	H	0.75	0.20	H	0.75	0.20	L	0.35	0.60	M	0.50	0.45
	$a_4$	L	0.35	0.60	L	0.35	0.60	H	0.75	0.20	L	0.35	0.60									
	$a_5$	M	0.50	0.45	L	0.35	0.60	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	L	0.35	0.60	M	0.50	0.45
	$a_6$	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20
$c_6$	$a_1$	H	0.75	0.20	VL	0.10	0.90	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	VL	0.10	0.90	H	0.75	0.20
	$a_2$	H	0.75	0.20	M	0.50	0.45	VL	0.10	0.90	VH	0.90	0.05	H	0.75	0.20	H	0.75	0.20	L	0.35	0.60
	$a_3$	H	0.75	0.20	L	0.35	0.60	VL	0.10	0.90	VH	0.90	0.05	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45
	$a_4$	VL	0.10	0.90	VL	0.10	0.90	M	0.50	0.45	L	0.35	0.60									
	$a_5$	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20	H	0.75	0.20	H	0.75	0.20	M	0.50	0.45
	$a_6$	VH	0.90	0.05	M	0.50	0.45	VL	0.10	0.90	VH	0.90	0.05	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45
$c_7$	$a_1$	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45
	$a_2$	VH	0.90	0.05	M	0.50	0.45	M	0.50	0.45	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45	M	0.50	0.45
	$a_3$	L	0.35	0.60	VH	0.90	0.05	M	0.50	0.45	H	0.75	0.20	VH	0.90	0.05	L	0.35	0.60	VL	0.10	0.90
	$a_4$	VL	0.10	0.90	VL	0.10	0.90	M	0.50	0.45	L	0.35	0.60	L	0.35	0.60	L	0.35	0.60	M	0.50	0.45
	$a_5$	L	0.35	0.60	L	0.35	0.60	M	0.50	0.45	VH	0.90	0.05	H	0.75	0.20	L	0.35	0.60	L	0.35	0.60
	$a_6$	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45	H	0.75	0.20	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45
$c_8$	$a_1$	VH	0.90	0.05	VH	0.90	0.05	H	0.75	0.20												
	$a_2$	H	0.75	0.20	M	0.50	0.45	H	0.75	0.20	H	0.75	0.20	H	0.75	0.20	M	0.50	0.45	M	0.50	0.45
	$a_3$	H	0.75	0.20	VL	0.10	0.90	M	0.50	0.45	H	0.75	0.20	VH	0.90	0.05	L	0.35	0.60	M	0.50	0.45
	$a_4$	L	0.35	0.60	L	0.35	0.60	M	0.50	0.45	L	0.35	0.60									
	$a_5$	L	0.35	0.60	L	0.35	0.60	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	L	0.35	0.60	M	0.50	0.45
	$a_6$	H	0.75	0.20	H	0.75	0.20	M	0.50	0.45	VH	0.90	0.05	VH	0.90	0.05	M	0.50	0.45	H	0.75	0.20
$c_9$	$a_1$	H	0.75	0.20	VL	0.10	0.90	VH	0.90	0.05	VL	0.10	0.90	VL	0.10	0.90	L	0.35	0.60	VL	0.10	0.90
	$a_2$	H	0.75	0.20	VH	0.90	0.05	L	0.35	0.60	VH	0.90	0.05	H	0.75	0.20	M	0.50	0.45	VL	0.10	0.90
	$a_3$	M	0.50	0.45	VL	0.10	0.90	L	0.35	0.60	VL	0.10	0.90	VL	0.10	0.90	L	0.35	0.60	VL	0.10	0.90
	$a_4$	L	0.35	0.60	VL	0.10	0.90	L	0.35	0.60												
	$a_5$	L	0.35	0.60	L	0.35	0.60	L	0.35	0.60	VL	0.10	0.90	M	0.50	0.45	L	0.35	0.60	VL	0.10	0.90
	$a_6$	VL	0.10	0.90	M	0.50	0.45	M	0.50	0.45	L	0.35	0.60	M	0.50	0.45	M	0.50	0.45	M	0.50	0.45

TABLE V  
AGGREGATION MATRIX OF  $a_1$  AND  $a_2$

	$a_1$			$a_2$		
	$\mu$	$\nu$	$\pi$	$\mu$	$\nu$	$\pi$
$c_1$	0.85	0.09	0.06	0.81	0.13	0.06
$c_2$	0.86	0.08	0.06	0.51	0.44	0.05
$c_3$	0.84	0.10	0.06	0.77	0.16	0.07
$c_4$	0.67	0.27	0.07	0.72	0.21	0.07
$c_5$	0.79	0.15	0.06	0.76	0.18	0.06
$c_6$	0.69	0.23	0.07			



TABLE VIII  
POSITIVE DISTANCE OF  $a_1$  AND  $a_2$

	$a_1$			$a_2$		
	$\mu$	$\nu$	$\pi$	$\mu$	$\nu$	$\pi$
$c_1$	0.00	0.00	0.00	0.00	0.00	0.00
$c_2$	0.00	0.00	0.00	0.09	0.11	0.00
$c_3$	0.00	0.00	0.00	0.00	0.00	0.00
$c_4$	0.01	0.01	0.00	0.00	0.00	0.00
$c_5$	0.00	0.00	0.00	0.00	0.00	0.00
$c_6$	0.00	0.00	0.00	0.00	0.00	0.00
$c_7$	0.00	0.00	0.00	0.00	0.00	0.00
$c_8$	0.00	0.00	0.00	0.01	0.01	0.00
$c_9$	0.02	0.03	0.00	0.00	0.00	0.00

TABLE IX  
NEGATIVE DISTANCE  $a_1$  AND  $a_2$

	$a_1$			$a_2$		
	$\mu$	$\nu$	$\pi$	$\mu$	$\nu$	$\pi$
$c_1$	0.04	0.03	0.00	0.02	0.02	0.00
$c_2$	0.09	0.11	0.00	0.00	0.00	0.00
$c_3$	0.12	0.14	0.00	0.09	0.11	0.00
$c_4$	0.07	0.10	0.00	0.08	0.12	0.00
$c_5$	0.07	0.08	0.00	0.06	0.07	0.00
$c_6$	0.04	0.05	0.00	0.03	0.04	0.00
$c_7$	0.05	0.06	0.00	0.05	0.07	0.00
$c_8$	0.11	0.12	0.00	0.05	0.05	0.00
$c_9$	0.07	0.10	0.00	0.17	0.23	0.00

[5] —, “The concept of a linguistic variable and its application to approximate reasoning,” *Information Sciences*, vol. 8, no. 3, pp. 199–249, 1975.

[6] S. H. Rubin, “Computing with words,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 29, no. 4, pp. 518–524, 1999.

[7] L. A. Zadeh, “Fuzzy logic= computing with words,” *IEEE Transactions on Fuzzy Systems*, vol. 4, no. 2, pp. 103–111, 1996.

[8] R. Montes, A. Sánchez, P. Villar, and F. Herrera, “A web tool to support decision making in the housing market using hesitant fuzzy linguistic term sets,” *Applied Soft Computing*, vol. 35, pp. 949–957, 2015.

[9] R. Montes, A. M. Sanchez, P. Villar, and F. Herrera, “Teranga go!: Carpooling collaborative consumption community with multi-criteria hesitant fuzzy linguistic term set opinions to build confidence and trust,” *Applied Soft Computing*, vol. 67, pp. 941–952, 2018.

[10] J. Mendel, L. A. Zadeh, E. Trillas, R. R. Yager, J. Lawry, H. Hagra, and S. Guadarrama, “What computing with words means to me,” *IEEE Computational Intelligence Magazine*, vol. 5, pp. 20–26, 2010.

[11] J. Morales, R. Montes, N. Zermeño, J. Duran, and F. Herrera, “The use of fuzzy linguistic information and fuzzy delphi method to validate by consensus a questionnaire in a blended-learning environment,” in *Information Processing and Management of Uncertainty in Knowledge-Based Systems. Applications*. Springer International Publishing, 2018, pp. 137–149.

[12] K. T. Atanassov, “Intuitionistic fuzzy sets,” *Fuzzy Sets and Systems*, vol. 20, no. 1, pp. 87–96, 1986.

[13] Z. Yue and Y. Jia, “A group decision making model with hybrid intuitionistic fuzzy information,” *Computers & Industrial Engineering*, vol. 87, pp. 202–212, 2015.

[14] K. T. Atanassov, “Operators over interval valued intuitionistic fuzzy sets,” *Fuzzy Sets and Systems*, vol. 64, no. 2, pp. 159–174, 1994.

[15] Z. Xu, “Intuitionistic fuzzy aggregation operators,” *IEEE Transactions on Fuzzy Systems*, vol. 15, no. 6, pp. 1179–1187, 2007.

[16] F. E. Boran, S. Genç, M. Kurt, and D. Akay, “A multi-criteria intuitionistic fuzzy group decision making for supplier selection with topsis method,” *Expert Systems with Applications*, vol. 36, no. 8, pp. 11 363–11 368, 2009.

[17] B. Rouyendegh, “Developing an integrated anp and intuitionistic fuzzy topsis model for supplier selection,” *Journal of Testing and Evaluation*, vol. 43, no. 3, pp. 664–672, 2015.

[18] E. Afful-Dadzie, Z. K. Oplatkova, and L. A. B. Prieto, “Comparative state-of-the-art survey of classical fuzzy set and intuitionistic fuzzy sets in multi-criteria decision making,” *International Journal of Fuzzy Systems*, vol. 19, no. 3, pp. 726–738, 2017.

[19] S. Shariati, M. Abedi, A. Saedi, A. Yazdani-Chamzini, J. Tamošaitienė, J. Šaparauskas, and S. Stupak, “Critical factors of the application of nanotechnology in construction industry by using anp technique under fuzzy intuitionistic environment,” *Journal of Civil Engineering and Management*, vol. 23, no. 7, pp. 914–925, 2017.

[20] Y. Yuan, T. Guan, X. Yan, and Y. Li, “Based on hybrid vikor method decision making model for supplier selection,” *Control and Decision*, vol. 29, no. 3, pp. 551–560, 2014.

[21] S. Ebrahimnejad, H. Hashemi, S. Mousavi, and B. Vahdani, “A new interval-valued intuitionistic fuzzy model to group decision making for the selection of outsourcing providers,” *Economic Computation & Economic Cybernetics Studies & Research*, vol. 49, no. 2, 2015.

[22] B. Pardha Saradhi, N. R. Shankar, and C. Suryanarayana, “Novel distance measure in fuzzy topsis for supply chain strategy based supplier selection,” *Mathematical Problems in Engineering*, vol. 2016, 2016.

[23] R. J. Kuo, C. W. Hsu, and Y. L. Chen, “Integration of fuzzy anp and fuzzy topsis for evaluating carbon performance of suppliers,” *International Journal of Environmental Science and Technology*, vol. 12, no. 12, pp. 3863–3876, 2015.

TABLE X  
RANKING OF WEB ACCESSIBILITY TEST TOOLS

Solution	$S^+$	$S^-$	$RP_{A_i}$	Ranking
$a_1$	0.062	0.287	0.822	1
$a_2$	0.118	0.269	0.694	2
$a_3$	0.185	0.197	0.516	5
$a_4$	0.303	0.042	0.122	6
$a_5$	0.175	0.192	0.523	4
$a_6$	0.115	0.253	0.689	3

# Estabilidad de las decisiones en el tiempo, ¿cómo medirla?

R. de Andrés Calle  
BORDA Research Unit,  
PRESAD Research Group and  
Multidisciplinary Institute of Enterprise  
University of Salamanca,  
E37007 Salamanca, Spain  
rocioac@usal.es

J.M. Cascón  
Department of Economics  
and Economic History  
Institute on Fundamental Physics  
and Mathematics  
University of Salamanca,  
E37007 Salamanca, Spain  
casbar@usal.es

T. González-Arteaga  
BORDA and PRESAD Research Groups  
Multidisciplinary Institute of Enterprise  
University of Valladolid,  
E47011 Valladolid, Spain  
teresa.gonzalez.arteaga@uva.es

**Resumen**—En esta contribución se propone un enfoque no tradicional en la medición de la estabilidad de las decisiones tomadas por los agentes a lo largo del tiempo. Esta contribución se centra en medir la estabilidad de las decisiones de los agentes en un contexto intertemporal bajo el supuesto de considerar las decisiones temporales como preordenes completos sobre las alternativas. Con este objetivo principal, se introduce el concepto general de *medida de la estabilidad de las decisiones intertemporales*, así como dos medidas particulares.

**Index Terms**—Estabilidad de las decisiones en el tiempo, preferencias intertemporales, preordenes, efecto pérdida de memoria

## I. INTRODUCCIÓN

El comportamiento humano implica decisiones intertemporales. En estas decisiones la persona debe evaluar los costes y los beneficios de decidir sobre un conjunto de alternativas en diferentes momentos del tiempo. Todos los días, los seres humanos tomamos decisiones intertemporales, por ejemplo cuando seleccionamos entre comer algo a media mañana o comer una comida completa a medio día o entre ir de vacaciones o aumentar la contribución al fondo de pensiones, etc.

El estudio de la elección intertemporal ha recibido atención desde diversas áreas de investigación como Economía, Psicología, Análisis de Decisión, Neurociencia, etc.

En términos generales, en la literatura especializada existen dos enfoques diferentes para tratar la medición de la estabilidad temporal de las decisiones de los individuos. El primero se centra en explorar las causas del comportamiento mediante procesos de optimización general (ver [1], [2] y [3], entre otros). En esta línea, es posible enmarcar los modelos económicos contemporáneos en los que los humanos toman decisiones intertemporales maximizando una función de utilidad de descuento exponencial. El segundo enfoque, proporcionado por los psicólogos, es el empírico. El comportamiento humano en las elecciones intertemporales se estudia mediante

datos empíricos recopilados de los laboratorios (ver [4], [5], [6] y [7]).

El objetivo de esta contribución es aportar un nuevo enfoque a la medición de la estabilidad de las decisiones intertemporales. En particular, se pretende desarrollar una nueva herramienta capaz de analizar el comportamiento humano en la toma de decisiones intertemporales y de medir la estabilidad de esas decisiones. Este trabajo está inspirado en la metodología propuesta por González-Arteaga, de Andrés Calle y Peral [8], [9] donde la noción de estabilidad de las decisiones intertemporales se considera en la misma línea que la noción de cohesión. En [8] los agentes establecen sus preferencias sobre una única alternativa de manera dicotómica. La suposición de opiniones dicotómicas y de considerar una única alternativa en este contexto particular podría limitar y perturbar los resultados del análisis del comportamiento debido a que la evidencia sugiere que los humanos pueden experimentar dificultades para expresar el conocimiento incierto de forma dicotómica [10].

En consecuencia, esta investigación se centra en un problema intertemporal de toma de decisiones bajo un marco general, es decir, los agentes expresan sus decisiones temporales sobre un conjunto finito de alternativas mediante preordenes completos en diferentes momentos de tiempo. Por tanto, el objetivo de esta aportación es determinar cuánto de estables son las decisiones de los agentes a lo largo del tiempo y para ello se define un nuevo concepto general, la *medida de estabilidad de decisiones* en el tiempo. Por otra parte, se proponen dos medidas específicas de estabilidad de las decisiones, la *medida local de estabilidad* y la *medida global de estabilidad*.

La estructura general de esta contribución se divide en tres secciones. La Sección II introduce la notación empleada así como los conceptos básicos utilizados. En la Sección III se define el concepto general de medida de estabilidad de las decisiones intertemporales. Además, en esta sección se introducen las dos clases específicas consideradas. En la Sección IV se incluye un ejemplo real sobre la estabilidad de las decisiones temporales en educación de algunos países basado en los datos procedentes del informe PISA. Finalmente

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad Proyecto ECO2016-77900-P (R. de Andrés Calle y T. González-Arteaga) y por la Conserjería de Educación de la Junta de Castilla y León Proyecto SA020U16 (J.M. Cascón).



se proporcionan algunas conclusiones e ideas sobre investigaciones futuras.

## II. NOTACIÓN

Sea  $\mathbf{N} = \{1, \dots, n\}$ ,  $n > 1$  un conjunto de individuos, expertos o miembros de una sociedad. Sea  $\mathbf{X} = \{x_1, \dots, x_k\}$  un conjunto finito de alternativas,  $|\mathbf{X}| \geq 2$ . Por simplicidad, en ocasiones la alternativa  $x_s$  será denotada por  $s$ .

Los miembros de la sociedad establecen sobre el conjunto de alternativas rankings mediante preordenes completos,  $\mathcal{R}$ .  $\mathbf{W}(\mathbf{X})$  denota el conjunto de todos los preordenes completos sobre  $\mathbf{X}$ .

Sea  $\mathcal{R} \in \mathbf{W}(\mathbf{X})$  un preorden completo, entonces  $x_i \succ_{\mathcal{R}} x_j$  significa que la alternativa  $x_i$  es estrictamente preferida a la alternativa  $x_j$ ,  $x_i \sim_{\mathcal{R}} x_j$  significa que las alternativas son igualmente preferidas y por último  $x_i \succeq_{\mathcal{R}} x_j$  significa que la alternativa  $x_i$  es al menos tan preferida como la alternativa  $x_j$ .

Denotaremos por  $\mathcal{R}_i \in \mathbf{W}(\mathbf{X})$  a la *decisión temporal* que la sociedad toma sobre el conjunto de alternativas  $\mathbf{X}$  en el momento del tiempo  $t_i \in \mathbf{T}$ ,  $\mathbf{T} = \{t_0, \dots, t_T\}$ . Una permutación  $\pi$  sobre las alternativas  $\{x_1, \dots, x_k\}$  determina otro preorden  ${}^{\pi}\mathcal{R}$  tal que:  $x_i \succeq_{\pi\mathcal{R}} x_j \iff x_{\pi^{-1}(i)} \succeq_{\mathcal{R}} x_{\pi^{-1}(j)}$  para  $i, j \in \{1, \dots, k\}$ .

Sea  $\mathcal{P} = (\mathcal{R}_0, \dots, \mathcal{R}_T) \in \mathbf{W}(\mathbf{X}) \times \dots \times \mathbf{W}(\mathbf{X}) = \mathbf{W}(\mathbf{X})^{T+1}$  un *perfil de decisión temporal* sobre el conjunto de alternativas  $\mathbf{X}$ . El elemento  $\mathcal{R}_i \in \mathcal{P}$  representa la decisión temporal de la sociedad sobre el conjunto de alternativas  $\mathbf{X}$  en el momento del tiempo  $t_i$ ,  $i \in \{0, \dots, T\}$ . El reverso del perfil de decisión temporal, denotado por  $\mathcal{P}^{-1}$ , es el perfil  $(\mathcal{R}_0^{-1}, \dots, \mathcal{R}_T^{-1})$  donde  $x_i \succeq_{\mathcal{R}_i^{-1}} x_j \iff x_j \succeq_{\mathcal{R}_i} x_i$ .

Una permutación  $\pi$  de las alternativas  $\{x_1, \dots, x_k\}$  determina un perfil de decisión temporal  ${}^{\pi}\mathcal{P}$  donde cada decisión temporal es permutada de acuerdo a  $\pi$ . Una permutación  $\sigma$  de los momentos del tiempo  $\{t_0, \dots, t_T\}$  determina una permutación sobre el perfil de decisión temporal  $\mathcal{P}^{\sigma}$  mediante la permutación de las decisiones temporales de acuerdo a  $\sigma$ .

Tratar con información ordinal implica necesariamente establecer de manera precisa la forma en que se representa. La primera discusión y análisis formal sobre la transformación de información ordinal en valores numéricos surgió con el trabajo de Borda [11]. Posteriormente, se han propuesto diversos procedimientos para este fin como [12], [13] y [14], entre otros.

La elección de un procedimiento de codificación robusto es un aspecto esencial para trabajar con información ordinal y obtener resultados consistentes. En esta contribución se utiliza el método de codificación propuesto en [15], el cuál está caracterizado.

Dada una decisión temporal  $\mathcal{R}_i \in \mathbf{W}(\mathbf{X})$ , su *vector de codificación canónica* es

$$\mathbf{c}_{\mathcal{R}_i} = (c_1^{\mathcal{R}_i}, \dots, c_k^{\mathcal{R}_i}) \in (\{1, \dots, k\})^k$$

donde  $c_j^{\mathcal{R}_i}$  es el número de alternativas que son clasificadas al menos tan buenas como  $x_j$  en el momento del tiempo  $t_i$ , esto es  $c_j^{\mathcal{R}_i} = |\{q : x_j \succeq_{\mathcal{R}_i} x_q\}|$ .

El conjunto de todas las posibles codificaciones canónicas asociadas a  $\mathbf{W}(\mathbf{X})$  es denotado por  $\mathbf{F} = \mathbf{F}(\mathbf{W}(\mathbf{X}))$ .

Dado un perfil de decisión temporal  $\mathcal{P} = (\mathcal{R}_0, \dots, \mathcal{R}_T) \in \mathbf{W}(\mathbf{X})^{T+1}$ , su *perfil de codificación canónica* es una matriz  $k \times (T+1)$ ,  $\mathcal{M}_{\mathcal{P}} = (\mathbf{c}_{\mathcal{R}_0}, \dots, \mathbf{c}_{\mathcal{R}_T}) \in \mathbb{M}_{k \times (T+1)}$  donde la columna  $i$ -ésima, denotada por  $\mathbf{c}_{\mathcal{R}_i}$  representa la codificación canónica de la decisión temporal  $\mathcal{R}_i$  en el momento  $t_i \in \mathbf{T}$ .

Una permutación  $\pi$  de las alternativas  $\{x_1, \dots, x_k\}$  determina un perfil de codificación canónica  ${}^{\pi}\mathcal{M}_{\mathcal{P}}$  mediante la permutación de las filas de  $\mathcal{M}_{\mathcal{P}}$ : la fila  $i$  del perfil  ${}^{\pi}\mathcal{M}_{\mathcal{P}}$  es la fila  $\pi(i)$  del perfil  $\mathcal{M}_{\mathcal{P}}$ . Una permutación  $\sigma$  de los momentos del tiempo  $\{t_0, \dots, t_T\}$  determina una permutación sobre el perfil de de codificación canónica  $\mathcal{M}_{\mathcal{P}}^{\sigma}$  mediante la permutación de las columnas de  $\mathcal{M}_{\mathcal{P}}$ : la columna  $i$  del perfil  $\mathcal{M}_{\mathcal{P}}^{\sigma}$  es la columna  $\sigma(i)$  del perfil  $\mathcal{M}_{\mathcal{P}}$ .

## III. MEDICIÓN DE LA ESTABILIDAD DE LAS DECISIONES EN EL TIEMPO

Esta sección está dedicada a introducir nuestra propuesta general para la medición de estabilidad de las decisiones a lo largo del tiempo, así como dos medias particulares.

*Definición 1:* Sea  $\mathcal{P} \in \mathbf{W}(\mathbf{X})^{T+1}$  un perfil de decisión temporal. Una *medida de estabilidad de las decisiones* en el tiempo sobre  $\mathcal{P} \in \mathbf{W}(\mathbf{X})^{T+1}$  es una función  $\mu : \mathbf{W}(\mathbf{X})^{T+1} \rightarrow [0, 1]$  que asigna a cada perfil de decisión temporal un valor en el intervalo unidad  $\mu(\mathcal{P})$  con las siguientes propiedades:

- i. Estabilidad máxima de la decisión:

$$\mu(\mathcal{P}) = 1 \iff \mathcal{R}_0 = \dots = \mathcal{R}_T$$

- ii. Neutralidad de la decisión sobre las alternativas:

$$\mu({}^{\pi}\mathcal{P}) = \mu(\mathcal{P})$$

para cada permutación  $\pi$  sobre el conjunto de las alternativas.

*Definición 2:* Sea  $\mathcal{P} = (\mathcal{R}_0, \dots, \mathcal{R}_T) \in \mathbf{W}(\mathbf{X})^{T+1}$  un perfil de decisión temporal y  $\mathcal{M}_{\mathcal{P}} = (\mathbf{c}_{\mathcal{R}_0}, \dots, \mathbf{c}_{\mathcal{R}_T}) \in \mathbb{M}_{k \times (T+1)}$  su correspondiente matriz de codificación canónica. La *medida local de estabilidad* entre las decisiones temporales  $\mathcal{R}_{i-1}$  y  $\mathcal{R}_i$  es una aplicación  $\theta_i : \mathbf{W}(\mathbf{X})^2 \rightarrow [0, 1]$  tal que

$$\theta_i(\mathcal{P}) = \theta_{[i-1, i]}(\mathcal{P}) = 1 - \frac{\|\mathbf{c}_{\mathcal{R}_{i-1}} - \mathbf{c}_{\mathcal{R}_i}\|_1}{r}$$

donde  $\mathbf{c}_{\mathcal{R}_{i-1}}$  y  $\mathbf{c}_{\mathcal{R}_i}$  son los vectores de codificación canónica asociados a las decisiones temporales tomadas en  $t_{i-1}$  y  $t_i$ , respectivamente;  $\|\cdot\|_1$  denota la norma  $l_1$ , y por tanto

$$\|\mathbf{c}_{\mathcal{R}_{i-1}} - \mathbf{c}_{\mathcal{R}_i}\|_1 = \sum_{h=1}^k |c_h^{\mathcal{R}_{i-1}} - c_h^{\mathcal{R}_i}|, \text{ finalmente}$$

$$r = \max_{\mathbf{c}, \mathbf{c}' \in \mathbf{F}} \|\mathbf{c} - \mathbf{c}'\|_1.$$

Por consiguiente:

$$\theta_i(\mathcal{P}) = \theta_{[i-1,i]}(\mathcal{P}) = 1 - \frac{\sum_{h=1}^k |c_h^{\mathcal{R}_{i-1}} - c_h^{\mathcal{R}_i}|}{\max_{\mathbf{c}, \mathbf{c}' \in \mathbf{F}} \|\mathbf{c} - \mathbf{c}'\|_1}$$

La medida local de estabilidad entre dos decisiones es una medida de estabilidad dado que verifica las propiedades:

i. Estabilidad máxima de la decisión:

$$\theta_i(\mathcal{P}) = \theta_{[i-1,i]}(\mathcal{P}) = 1 \iff \mathcal{R}_{i-1} = \mathcal{R}_i$$

ii. Neutralidad de la decisión sobre las alternativas:

$$\theta_i(\pi\mathcal{P}) = \theta_{[i-1,i]}(\pi\mathcal{P}) = \theta_{i-1,i}(\mathcal{P}) = \theta_i(\mathcal{P})$$

para cada permutación  $\pi$  sobre las alternativas  $\{1, \dots, k\}$ .

*Proposición 1:* La máxima inestabilidad entre dos decisiones temporales viene dada por el diámetro de la envolvente convexa del conjunto de todas las codificaciones canónicas asociadas a  $\mathbf{W}(\mathbf{X})$ , i.e.,  $\mathbf{F} = \mathbf{F}(\mathbf{X})$  para la norma  $l_1$ :

$$r = \max_{u, v \in \text{Conv}(\mathbf{F})} \|u - v\|_1$$

donde

$$\text{Conv}(\mathbf{F}) = \left\{ \sum_{j=1}^{|\mathbf{F}|} \alpha_j \cdot \mathbf{c}_j : 0 \leq \alpha_j \leq 1, \sum_{j=1}^{|\mathbf{F}|} \alpha_j = 1 \right\}.$$

*Proposición 2:* La máxima inestabilidad entre dos decisiones temporales esta determinada por las siguientes expresiones:

■ Para  $\mathbf{X} = \{x_1, \dots, x_k\}$  con  $k$  par:

$$r = \frac{3}{4}k^2 - \frac{k}{2}$$

■ Para  $\mathbf{X} = \{x_1, \dots, x_k\}$  con  $k$  impar:

$$r = \frac{3}{4}k^2 - \frac{k}{2} - \frac{1}{4}$$

Con el objetivo de mejorar la comprensión de la notación y de las definiciones introducidas, se presenta el siguiente ejemplo ilustrativo.

*Ejemplo 1:* Sea  $\mathbf{X} = \{x_1, x_2, x_3\}$  un conjunto de tres alternativas ( $k = 3$ ). Todos los posibles preordenes,  $\mathcal{R} \in \mathbf{W}(\mathbf{X})$ , para esas tres alternativas están recogidos en la primera columna de la Tabla 1. La segunda columna incluye la codificación canónica de estos preordenes,  $\mathbf{c}_{\mathcal{R}}$ .

Supongamos ahora dos momentos en el tiempo  $t_1$  y  $t_2$  donde se han tomado las decisiones temporales  $\mathcal{R}_1$  y  $\mathcal{R}_2$ , respectivamente.

$$\mathcal{R}_1 : x_1 \sim x_2 \succ x_3$$

$$\mathcal{R}_2 : x_1 \succ x_2 \succ x_3$$

$\mathcal{R}$	$\mathbf{c}_{\mathcal{R}}$
$x_1 \sim x_2 \sim x_3$	(3, 3, 3)
$x_1 \sim x_2 \succ x_3$	(3, 3, 1)
$x_1 \succ x_2 \sim x_3$	(3, 2, 2)
$x_2 \succ x_1 \sim x_3$	(2, 3, 2)
$x_3 \succ x_1 \sim x_2$	(2, 2, 3)
$x_1 \succ x_2 \succ x_3$	(3, 2, 1)
$x_1 \succ x_3 \succ x_2$	(3, 1, 2)
$x_2 \succ x_1 \succ x_3$	(2, 3, 1)
$x_2 \succ x_3 \succ x_1$	(1, 3, 2)
$x_3 \succ x_1 \succ x_2$	(2, 1, 3)
$x_3 \succ x_2 \succ x_1$	(1, 2, 3)

Cuadro I: Preordenes y codificación canónica para  $k = 3$ .

Para analizar el nivel de estabilidad de las decisiones tomadas en  $t_1$  y  $t_2$  se utiliza la medida local de estabilidad proporcionada por la Definición 2:

$$\theta_2(\mathcal{P}) = \theta_{[1,2]}(\mathcal{P}) = 1 - \frac{\sum_{h=1}^3 |c_h^{\mathcal{R}_1} - c_h^{\mathcal{R}_2}|}{\max_{\mathbf{c}, \mathbf{c}' \in \mathbf{F}} \|\mathbf{c} - \mathbf{c}'\|_1}$$

En este caso, la envolvente convexa del conjunto de todas las codificaciones canónicas está representada desde diferentes perspectivas en las Figuras 1 y 2.

Aplicando los resultados de las Proposiciones 1 y 2, el diámetro de esta envolvente convexa viene dado por la expresión:

$$r = \frac{3}{4}k^2 - \frac{k}{2} - \frac{1}{4} = \frac{3}{4} \cdot 3^2 - \frac{3}{2} - \frac{1}{4} = 5$$

Por tanto la estabilidad local de las decisiones  $\mathcal{R}_1$  y  $\mathcal{R}_2$  es:

$$\theta_2(\mathcal{P}) = 1 - \frac{|3-3| + |3-2| + |1-1|}{5} = 0.8$$

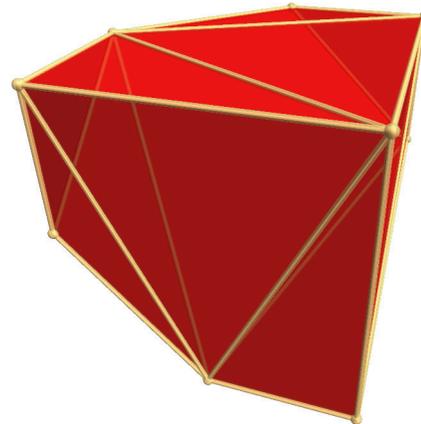


Figura 1: Representación de la envolvente convexa para  $k = 3$

*Definición 3:* Sea  $\mathcal{P} = (\mathcal{R}_0, \dots, \mathcal{R}_T) \in \mathbf{W}(\mathbf{X})^T$  un perfil de decisión temporal y  $\mathcal{M}_{\mathcal{P}} = (\mathbf{c}_{\mathcal{R}_0}, \dots, \mathbf{c}_{\mathcal{R}_T}) \in \mathbb{M}_{k \times (T+1)}$

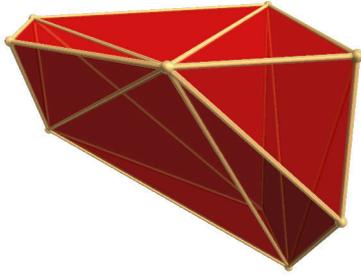


Figura 2: Representación de la envolvente convexa para  $k = 3$

su correspondiente matriz de codificación canónica. La *medida global de estabilidad de las decisiones* en el tiempo sobre  $\mathcal{P} \in \mathbf{W}(\mathbf{X})^{T+1}$  es una función  $\Theta : W(x)^{T+1} \times R^+ \rightarrow [0, 1]$  definida por:

$$\Theta(\mathcal{P}, \lambda) = \sum_{i=1}^T w_i \cdot \theta_i(\mathcal{P}) = \sum_{i=1}^T w_{[i-1, i]} \cdot \theta_{[i-1, i]}(\mathcal{P})$$

donde  $w_i = w_{[i-1, i]} = A \cdot e^{-\lambda(T-i+1)}$ ,  $A = \frac{e^\lambda - 1}{1 - e^{-\lambda T}}$  con  $\sum_{i=1}^T w_i = 1$  y  $\lambda \geq 0$ .

El parámetro  $\lambda$  recoge el efecto pérdida de memoria. Cuando  $\lambda = 0$  los agentes recuerdan las decisiones tomadas en todos los momentos del tiempo con la misma intensidad. Mientras que cuando  $\lambda > 0$ , los agentes tienen un efecto pérdida de memoria positivo, esto es, los agentes recuerdan con mayor intensidad las últimas decisiones.

La medida global de estabilidad de las decisiones es una medida de estabilidad de decisiones dado que verifica las propiedades:

- i. Estabilidad máxima de la decisión:

$$\Theta(\mathcal{P}, \lambda) = 1 \iff \mathcal{R}_0 = \dots = \mathcal{R}_T$$

- ii. Neutralidad de la decisión sobre las alternativas:

$$\Theta(\pi\mathcal{P}, \lambda) = \Theta(\mathcal{P}, \lambda)$$

para cada permutación  $\pi$  sobre las alternativas  $\{1, \dots, k\}$ .

El cumplimiento de estas propiedades por parte de la medida global es consecuencia directa del cumplimiento de las mismas por parte de la medida local.

#### IV. CASO DE ESTUDIO: ESTABILIDAD DE DECISIONES EN EDUCACIÓN

Con el objetivo de poner en relieve la aplicabilidad de la metodología propuesta, en esta sección se presenta un caso real de estudio. En concreto, se analiza y se mide la estabilidad a lo largo del tiempo de los rankings sobre rendimiento académico

proporcionados por el informe PISA<sup>1</sup> cada tres años a nivel mundial.

El informe PISA es un estudio realizado por la OCDE desde el año 2000 cuyo objetivo principal es evaluar el rendimiento académico de estudiantes en Matemáticas, Ciencias y comprensión lectora<sup>2</sup>. Mediante la realización de este informe la OCDE proporciona datos comparables que permiten a los diversos países mejorar sus políticas de educación.

Para realizar el estudio de caso sobre la estabilidad de las decisiones temporales de los países en Educación se han utilizado los datos proporcionados por el informe PISA para los años 2000, 2003, 2006, 2009, 2012 y 2015 para 25 países<sup>3</sup>.

En las Tablas II, IV y III se muestran los rankings sobre los países analizados en las tres habilidades incluidas en el informe: Matemáticas, comprensión lectora y Ciencias, respectivamente. Estos rankings constituyen los distintos perfiles de decisión temporal teniendo en cuenta la totalidad de estudiantes.

Además de considerar estos rankings, en esta contribución se ha analizado la estabilidad intertemporal de los rankings proporcionados por el informe PISA según el sexo de los estudiantes aunque los perfiles correspondientes no se detallan en esta contribución.

Por otra parte y para analizar como el efecto pérdida de memoria afecta a la estabilidad de las decisiones intertemporales se han considerado cinco valores diferentes del parámetro  $\lambda$ : 0, 0.25, 0.5, 0.75 y 1. Los resultados se muestran en la Tabla V y en las Figuras IV, IV y IV.

Tal y como se puede comprobar en la Tabla V y en las Figuras IV, IV y IV, la medida de estabilidad toma valores bastante altos en todos los países situándose entorno al (0.8 – 0.9) independientemente del valor de  $\lambda$ . La independencia de los resultados con respecto al parámetro puede deberse a que los cambios que afectan al nivel educativo de los países se perciben de forma lenta y no drástica, lo que es un claro indicativo de la estabilidad de las mediciones.

#### V. CONCLUSIONES Y TRABAJOS FUTUROS

La investigación sobre la estabilidad de las decisiones intertemporales se ha realizado principalmente en Economía. El objetivo del presente trabajo es proporcionar una nueva metodología desde una perspectiva no tradicional al problema de medir la estabilidad de las decisiones a lo largo del tiempo. La contribución se centra en un marco de evaluación donde los agentes expresan sus opiniones sobre diferentes alternativas en diferentes momentos del tiempo mediante preordenes completos. Se introduce la noción general de medida de

<sup>1</sup>Programa Internacional para la Evaluación de Estudiantes.

<sup>2</sup>El estudio se basa en el análisis del rendimiento de estudiantes de 15 años a partir exámenes estandarizados.

<sup>3</sup>AUS= Australia, BEL = Bélgica, BRA = Brasil, CAN = Canada, CHE = Suiza, CZE = República Checa, DEU = Alemania, DNK = Dinamarca, ESP = España, FIN = Finlandia, FRA = Francia, GRC = Grecia, HUN = Hungría, IDN = Indonesia, IRL = Irlanda, ISL = Islandia, ITA = Italia, JPN = Japón, KOR = Corea del Sur, MEX = México, NOR = Noruega, NZL = Nueva Zelanda, POL = Polonia, PRT = Portugal, SWE = Suecia.



2003	2006	2009	2012	2015
FIN	FIN	KOR	KOR	JPN
KOR	KOR	FIN	JPN	KOR
JPN	CHE	CHE	CHE	CHE
CAN	CAN	JPN	FIN	CAN
BEL	JPN	CAN	CAN, POL	DNK, FIN
CHE	NZL	NZL	BEL	BEL
AUS	AUS, BEL	BEL	DEU	DEU
NZL	DNK	AUS	AUS	IRL, POL
CZE	CZE	DEU	IRL	NOR
ISL	ISL	ISL	DNK, NZL	NZL
DNK	DEU	DNK	CZE	AUS, SWE
FRA	SWE	NOR	FRA	FRA
SWE	IRL	FRA	ISL	CZE, PRT
DEU, IRL	FRA	POL	NOR	ITA
NOR	POL	SWE	PRT	ISL
HUN, HUN	POL	CZE	ITA	ESP
ESP	NOR	HUN	ESP	HUN
ITA, PRT	ESP	IRL, PRT	SWE	GRC
GRC	PRT	ESP, ITA	HUN	MEX
MEX	ITA	GRC	GRC	IDN
IDN	GRC	MEX	MEX	BRA
BRA	MEX	BRA	BRA	
	IDN	MEX	IDN	
	BRA			

Cuadro II: Rankings de los países en distintos años en Matemáticas

2006	2009	2012	2015
FIN	FIN	JPN	JPN
CAN	JPN	FIN	FIN
JPN	KOR	KOR	CAN
NZL	NZL	POL	KOR
AUS	CAN	CAN	NZL
KOR	AUS	DEU	AUS
DEU	DEU	IRL	DEU
CZE	CHE	AUS	CHE
CHE	IRL, POL	NZL	IRL
BEL	BEL	CHE	BEL, DNK
IRL	HUN	CZE	POL, PRT
HUN	CZE	BEL	NOR
SWE	NOR	FRA	FRA
POL	DNK	DNK	CZE, ESP, SWE
DNK	FRA	ESP	ITA
FRA	ISL	NOR	HUN
ISL	SWE	HUN, ITA	ISL
ESP	PRT	PRT	GRC
NOR	ITA	SWE	MEX
ITA	ESP	ISL	IDN
PRT	GRC	GRC	BRA
GRC	MEX	MEX	
MEX	BRA	BRA	
IDN	IDN	IDN	
BRA			

Cuadro III: Rankings de los países en distintos años en Ciencias

estabilidad de las decisiones intertemporales así como dos formulaciones específicas, una de ellas prestando especial atención a cualesquiera dos sucesivos momentos de tiempo. Finalmente la metodología propuesta se aplica al caso de la estabilidad de las decisiones de los países respecto a la Educación según informes de la OCDE.

En cuanto a las futuras líneas de investigación, existen diversos aspectos que podrían ser analizados. Por una parte, la línea de actuación más inmediata sería la aplicación de la novedosa propuesta de esta contribución a una amplia gama de campos tales como la estabilidad de las decisiones de los

2000	2003	2006	2009	2012	2015
FIN	FIN	KOR	KOR	JPN	CAN
CAN	KOR	FIN	FIN	KOR	FIN
NZL	CAN	CAN	CAN	FIN	IRL
AUS	AUS	NZL	NZL	CAN, IRL	KOR
IRL	NZL	IRL	JPN	pol	JPN
KOR	IRL	AUS	AUS	AUS, NZL	NOR
JPN	SWE	POL	BEL	BEL, CHE	DEU, NZL
SWE	BEL	SWE	NOR	DEU	POL
BEL, ISL	NOR	BEL	CHE	FRA	AUS
FRA, NOR	CHE	CHE	ISL, POL	NOR	DNK, SWE
DNK	JPN	JPN	DEU, SWE	DNK	BEL, FRA
CHE	POL	DEU	FRA, IRL	CZE	PRT
ESP	FRA	DNK	DNK	ITA	ESP
CZE	DNK, ISL	FRA	HUN	ESP, HUN, PRT	CHE
ITA	DEU	ISL, NOR	PRT	ISL, SWE	CZE
DEU	CZE	CZE	ITA	GRC	ITA
HUN	HUN	HUN	GRC	MEX	ISL
POL	ESP	PRT	ESP	BRA	HUN
GRC	PRT	ITA	CZE	IDN	GRC
PRT	ITA	ESP	MEX		MEX
MEX	GRC	GRC	BRA		BRA
BRA	BRA	MEX	IDN		IDN
IDN	MEX	BRA			
	IDN	IDN			

Cuadro IV: Rankings de los países en distintos años en comprensión lectora

	$\lambda = 0$		
	Total	Chicas	Chicos
Matemáticas	0.912829	0.893640	0.887610
Ciencias	0.894006	0.879386	0.886696
Lectura	0.879386	0.867105	0.868860
	$\lambda = 0.25$		
	Total	Chicas	Chicos
Matemáticas	0.907834	0.890512	0.884263
Ciencias	0.891127	0.875995	0.883674
Lectura	0.872121	0.864099	0.859995
	$\lambda = 0.5$		
	Total	Niñas	Niños
Matemáticas	0.904190	0.888388	0.882652
Ciencias	0.888446	0.872551	0.880929
Lectura	0.865605	0.861989	0.852755
	$\lambda = 0.75$		
	Total	Chicas	Chicos
Matemáticas	0.901939	0.887243	0.882537
Ciencias	0.886087	0.869262	0.878575
Lectura	0.860759	0.860896	0.847942
	$\lambda = 1$		
	Total	Chicas	Chicos
Matemáticas	0.900816	0.886851	0.883424
Ciencias	0.884109	0.866284	0.876654
Lectura	0.857641	0.860587	0.845295

Cuadro V: Valores de la medida global de estabilidad de las decisiones intertemporales

consumidores, decisiones de inversión, etc. Por otra parte, la metodología propuesta podría ser extendida a un horizonte temporal infinito.

REFERENCIAS

[1] P. Samuelson, "A note on measurement of utility," *The Review of Economic Studies*, vol. 4, no. 2, pp. 155-161, 1937.  
 [2] M. Bateson and A. Kacelnik, "Rate currencies and the foraging starling: the fallacy of the averages revisited," *Behavioral Ecology*, vol. 7, no. 3, pp. 341-352, 1996.

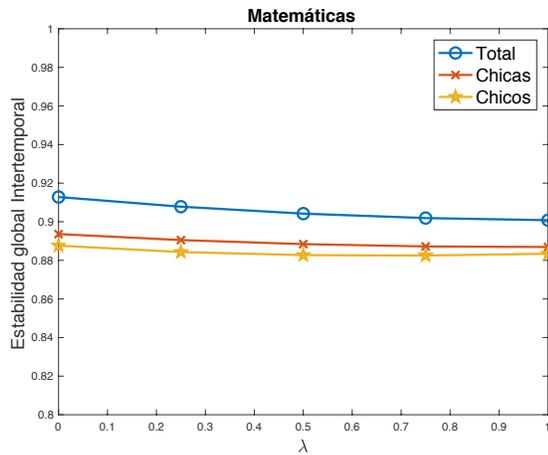


Figura 3: Estabilidad global intertemporal de las decisiones en Matemáticas para diferentes valores de  $\lambda$

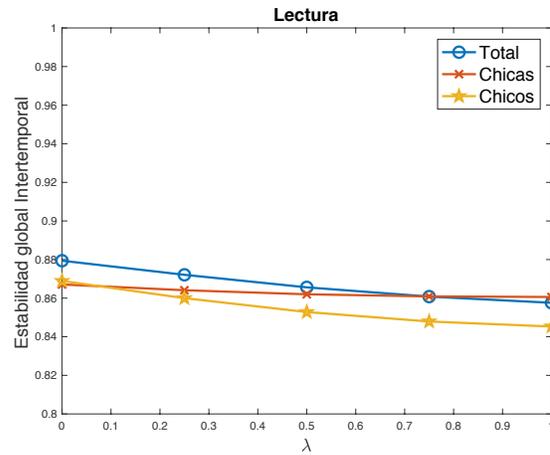


Figura 5: Estabilidad global intertemporal de las decisiones en comprensión lectora para diferentes valores de  $\lambda$

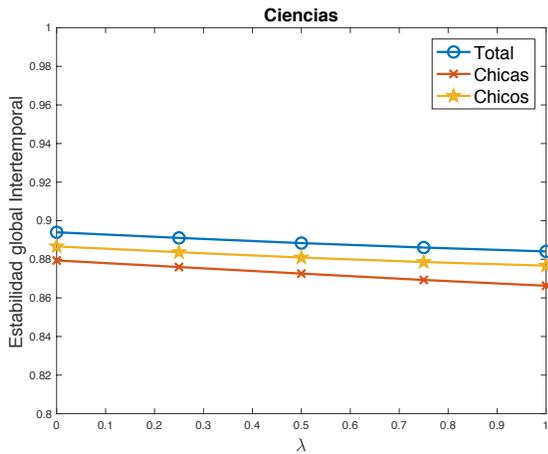


Figura 4: Estabilidad global intertemporal de las decisiones en Ciencias para diferentes valores de  $\lambda$

1965.

[11] J. Borda, *Mémoire sur les Elections au Scrutin*. Paris: Histoire de l'Academie Royale des Sciences, 1781.

[12] D. Black, "Partial justification of the Borda count," *Public Choice*, vol. 28, pp. 1–16, 1976.

[13] W. Cook and L. Seiford, "On the Borda–Kendall consensus method for priority ranking problems," *Management Science*, vol. 28, pp. 621–637, 1982.

[14] J. L. García-Lapresta and D. Pérez-Román, "Measuring consensus in weak orders," in *Consensual Processes*, ser. Studies in Fuzziness and Soft Computing, E. Herrera-Viedma, J. L. García-Lapresta, J. Kacprzyk, M. Fedrizzi, H. Nurmi, and S. Zadrozny, Eds. Springer Berlin Heidelberg, 2011, vol. 267, pp. 213–234.

[15] T. González-Arteaga, R. de Andrés Calle, and J. Alcantud, "A new consensus ranking approach for correlated ordinal information based on Mahalanobis distance," *Information Sciences*, vol. 372, no. Supplement C, pp. 546 – 564, 2016.

[3] D. Stephens and D. Anderson, "The adaptive value of preference for immediacy: when shortsighted rules have farsighted consequences," *Behavioral Ecology*, vol. 12, no. 3, pp. 330–339, 2001.

[4] J. Alcock and P. Sherman, "The utility of the proximate-ultimate dichotomy in ethology," *Ethology*, vol. 96, no. 1, pp. 58–62, 1994.

[5] S. Kim, J. Hwang, and D. Lee, "Prefrontal coding of temporally discounted values during intertemporal choice," *Neuron*, vol. 59, no. 1, pp. 161 – 172, 2008.

[6] J. Peters and C. Büchel, "Overlapping and distinct neural systems code for subjective value during intertemporal and risky decision making," *Journal of Neuroscience*, vol. 29, no. 50, pp. 15 727–15 734, 2009.

[7] S. Kim and D. Lee, "Prefrontal cortex and impulsive decision making," *Biological Psychiatry*, vol. 69, no. 12, pp. 1140 – 1146, 2011, prefrontal Cortical Circuits Regulating Attention, Behavior and Emotion.

[8] T. González-Arteaga, R. de Andrés Calle, and M. Peral, "Preference stability along time: the time cohesiveness measure," *Progress in Artificial Intelligence*, vol. 6, no. 3, pp. 235–244, 2017.

[9] T. González-Arteaga and R. de Andrés Calle, "New approach to measure preference stability," in *2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, July 2017, pp. 1–6.

[10] L. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, pp. 338–375,

# Some remarks on “Preference stability over time: The time cohesiveness measure”

Teresa González-Arteaga  
BORDA and PRESAD Research Groups  
University of Valladolid  
E47011 Valladolid, Spain  
teresa.gonzalez.arteaga@uva.es

Rocío de Andrés Calle  
BORDA Research Unit  
PRESAD Research Group  
Multidisciplinary Institute of Enterprise  
University of Salamanca  
E37007 Salamanca, Spain  
rocioac@usal.es

**Abstract**—This work introduces a non-traditional approach about the problem of measuring the stability of agents’ preferences over time under the assumption of considering dichotomous opinions. The general concept of *time cohesiveness measure* is introduced as well as a particular formulation based on the consideration of any two successive moments of time, the *sequential time cohesiveness measure*. Moreover, some properties of the novel measure are also provided. Finally, a case of study is presented. This essay presents the main contributions of the paper entitled “Preference stability along time: The time cohesiveness measure” published in the journal *Progress in Artificial Intelligence*.

**Index Terms**—Time cohesiveness measure; Dichotomous opinions; Preference stability; Patients’ preferences

## I. INTRODUCTION

Intertemporal decision making is an important research area and it has been obtaining attention from several research fields such as Economics, Health Economics, Social Choice, Psychology, Marketing, Decision Analysis, Neuroscience, and so on. One of the main topics of this area is the study of preference stability over time. Traditionally, intertemporal preferences have usually been considered permanent by theoretical and empirical studies (see [1], [2] and [3], among other) and the research to date has tend to explore preference stability over time by means of statistical methods.

In order to enhance the preference stability topic, the aim of this contribution is to develop a new tool capable of measuring preference stability from a non-traditional perspective. For this purpose, the notion of preference stability is considered in the same vein that the notion of cohesiveness. This seems natural because the measurement of preference stability resembles the notion of measurement of cohesiveness over time in the sense that the maximum value captures the notion of full stability, that is, unanimity along time, while the minimum value captures the notion of total lack of stability, that is, total disagreement along time.

Taking into account the previous contributions on preference stability and cohesiveness measure, this paper is focused on an intertemporal decision-making problem where a set of agents express their opinions on an alternative along different

moments of time. To be precise, agents have to approve or disapprove the alternative under study at diverse points of time. Thus, the paper objective is to determine how much stability or cohesiveness agents opinions conveys to the group on the alternative along time. In order to measure such stability, a new general approach is defined, the *time cohesiveness measure*. Moreover, an specific formulation of the time cohesiveness measure is introduced, the *sequential time cohesiveness measure* as well as a study of its analytic properties. Under this approach, the stability of preferences is understood like the probability that for a randomly chosen moment of time, two randomly chosen agents have the same opinion at such a time and its consecutive.

Furthermore, the measurement proposed is put in practice in a real case of study to emphasize its applicability. In particular, the stability of preferences for life-sustaining treatments in terminally cancer patients’ last year of life is analysed.

This contribution is structured as follows. Section 2 introduces the notation and the novel proposals to measure preference stability. Section 3 includes a brief description of the paper application. Finally, some closing comments are provided.

## II. THE TIME COHESIVENESS MEASURE: NOTATION AND DEFINITIONS

Let  $\mathbf{N} = \{1, 2, \dots, N\}$  a set of agents or experts. Agents express their opinions on an alternative,  $x$ , at different time moments  $\mathbf{T} = \{t_1, \dots, t_T\}$  by means of dichotomous opinions.

A *time preference profile* of a set of agents  $\mathbf{N}$  on an alternative  $x$  at  $T$  different time moments is a matrix  $\mathbf{P} = (P_{it_j})_{N \times T}$  where  $P_{it_j}$  is the opinion of the agent  $i$  over alternative  $x$  at  $t_j$  moment, in the sense

$$P_{it_j} = \begin{cases} 1 & \text{if agent } i \text{ approves } x \text{ at the } t_j \text{ time,} \\ 0 & \text{otherwise.} \end{cases}$$

Let  $\mathbb{P}_{N \times T}$  denote the set of all such  $N \times T$  matrices.

A time preference profile  $\mathbf{P}$  is *unanimous* if alternative  $x$  is approved (resp. disapproved) over  $\mathbf{T}$  by all agents. In matrix terms, if the time preference profile  $\mathbf{P} \in \mathbb{P}_{N \times T}$  is constant,  $\mathbf{P} = (1)_{N \times T}$  (resp.  $\mathbf{P} =$

The authors acknowledge financial support by the Spanish Ministerio de Ciencia e Innovación under Project Project ECO2016-77900-P.



$(0)_{N \times T}$ ). Any permutation  $\sigma$  of the agents  $\{1, 2, \dots, N\}$  determines a time preference profile  $\mathbf{P}^\sigma$  by permutation of the rows of  $\mathbf{P}$ , that is, row  $i$  of the profile  $\mathbf{P}^\sigma$  is row  $\sigma(i)$  of the profile  $\mathbf{P}$ .

*Definition 1:* A *time cohesiveness measure* for a group of agents  $\mathbf{N} = \{1, \dots, N\}$  on an alternative  $x$  is a mapping  $\tau : \mathbb{P}_{N \times T} \rightarrow [0, 1]$  that assigns a number  $\tau(\mathbf{P}) \in [0, 1]$  to each time preference profile  $\mathbf{P}$ , with the properties:

- i)  $\tau(\mathbf{P}) = 1$  if and only if  $\mathbf{P}$  is unanimous (full stability).
- ii)  $\tau(\mathbf{P}^\sigma) = \tau(\mathbf{P})$  for each permutation  $\sigma$  of the agents and  $\mathbf{P} \in \mathbb{P}_{N \times T}$  (anonymity).

*Definition 2:* The *sequential time cohesiveness measure* for a group of agents  $\mathbf{N} = \{1, \dots, N\}$  on an alternative  $x$  is the mapping  $\tau_S : \mathbb{P}_{N \times T} \rightarrow [0, 1]$  given by

$$\tau_S(\mathbf{P}) = \sum_{b \in \{0,1\}} \frac{1}{T-1} \cdot \frac{\sum_{j=1}^{T-1} n_{b,b}^{t_j, t_{j+1}} \cdot (n_{b,b}^{t_j, t_{j+1}} - 1)}{N(N-1)}$$

where  $n_{0,0}^{t_j, t_{j+1}}$  denotes the number of agents that disapprove alternative  $x$  at  $t_j$  and keep their opinion at the following point of time  $t_{j+1}$ . Similarly,  $n_{1,1}^{t_j, t_{j+1}}$  denotes the number of agents that approve alternative  $x$  at  $t_j$  and keep their opinion at the following point of time  $t_{j+1}$ .

Intuitively, it measures the probability that for a randomly chosen moment of time, two randomly chosen agents of a group have the same opinion upon an alternative at the moment of time selected and its consecutive.

The sequential cohesiveness measure verifies the following meaningful properties: reversal invariance, time-reducibility, replication monotonicity, minimum time stability, leaving minimum time stability, time monotonicity and convergence to full stability.

### III. A CASE STUDY OF PREFERENCE STABILITY IN CLINICAL DECISION MAKING

So as to implement our proposal for measuring the stability of preferences over time of a group of agents, this contribution is inspired and motivated by the study of Tang et al. [4]. In [4], the authors examined the stability of life-sustaining treatment preferences at end of life of cancer patient's last year by means of an statistical approach. Authors collected patients' preferences about life support choices by the *Life Support Preferences Questionnaire* (LSPQ) [5].

Based on this study, a finite set of 257 patients is considered in this contribution. These patients expressed their opinions by dichotomous opinions on a finite set of 3 treatments for life-sustaining at end of life being: cardiopulmonary resuscitation (CPR), dying in an intensive care unit (ICU) and mechanical ventilation support (MSV). Patients expressed their preferences about approving or disapproving the aforementioned treatments at four different time moments along their illness. Thus, patients' opinions can be formalized by means of a time preference profile for each treatment  $\mathbf{P}^{CPR}$ ,  $\mathbf{P}^{ICU}$  and

Treatment	$n_{0,0}^{t_1, t_2}$	$n_{1,1}^{t_1, t_2}$	$n_{0,0}^{t_2, t_3}$	$n_{1,1}^{t_2, t_3}$	$n_{0,0}^{t_3, t_4}$	$n_{1,1}^{t_3, t_4}$
CPR	190	34	210	24	228	15
ICU	142	79	156	63	184	26
MSV	170	44	187	38	209	25

Table I: Number of patients that approve and disapprove different treatments at different moments of time

$\mathbf{P}^{MSV}$ . The information provided by the three previous time preference profiles can be group in Table I.

Using Definition 2, the sequential time cohesiveness measure for each profile, that is, for each treatment can be computed. Table II shows such values including all moments of time and all patients.

Treatment	Profile	$\tau_S(\mathbf{P})$
CPR	$\mathbf{P}^{CPR}$	0.676
ICU	$\mathbf{P}^{ICU}$	0.449
MVS	$\mathbf{P}^{MVS}$	0.562

Table II: Values of the sequential time cohesiveness measure for each treatment

Moreover, these results were explored in depth in [6]. The set of patients was partitioned, differentiating between patients with and without metastases.

### IV. CLOSING COMMENTS

In this work, a non-traditional perspective on preference stability topic is set out. The problem of measuring the degree of cohesiveness in a setting where agents express their opinions on an alternative at different times by means of an approval or disapproval evaluation is explored. A general concept of *time cohesiveness measure* is introduced and a particular formulation based on the consideration of any two successive times is proposed, namely *the sequential time cohesiveness measure*. Some properties which make our proposal appealing are also provided. The applicability of our proposal to real situations is emphasized by means of adapting a factual problem in Clinical Decision Making. Concretely, the case of terminally cancer patients' last year of life is studied using the new sequential time cohesiveness measure.

### REFERENCES

- [1] G. Loewenstein and E. Angner, *Predicting and indulging changing preferences*, 2003.
- [2] S. Meier and C. Sprenger, "Temporal stability of time preferences," *Review of Economics and Statistics*, vol. 97, no. 2, pp. 273–286, 2015.
- [3] A. Reynaud and S. Couture, "Stability of risk preference measures: Results from a field experiment on french farmers," *Theory and Decision*, vol. 73, no. 2, pp. 203–221, 2012.
- [4] S. T. Tang, F.-H. Wen, C.-H. Hsieh, W.-C. Chou, W.-C. Chang, J.-S. Chen, and M.-C. Chiang, "Preferences for life-sustaining treatments and associations with accurate prognostic awareness and depressive symptoms in terminally ill cancer patients' last year of life," *Journal of Pain and Symptom Management*, vol. 51, no. 1, pp. 41–51, 2016.
- [5] D. K. Beland and R. D. Froman, "Preliminary validation of a measure of life support preferences," *Journal of Nursing Scholarship*, vol. 27, no. 4, pp. 307–310, 1995.
- [6] T. González-Artega, R. de Andrés Calle, and M. Peral, "Preference stability along time: the time cohesiveness measure," *Progress in Artificial Intelligence*, vol. 6, no. 3, pp. 235–244, 2017.

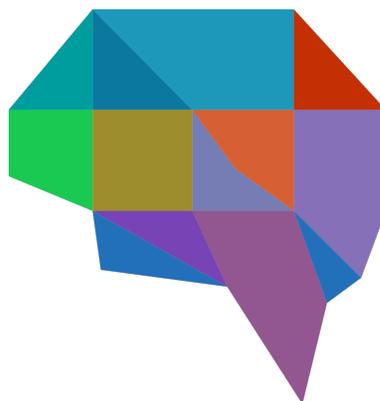


# **XIX Congreso Español sobre Tecnologías y Lógica Fuzzy (XIX ESTYLF)**

**ESTYLF 11: SESIÓN ESPECIAL  
SOFT COMPUTING Y  
GENERACIÓN DEL  
LENGUAJE NATURAL I**

**Organizadores:**

ALBERTO BUGARÍN, NICOLÁS MARÍN,  
ALEJANDRO RAMOS, DANIEL SÁNCHEZ







# Modelado borroso de referencias geográficas textuales sobre datos de expertos

A. Ramos-Soto<sup>\*†</sup>, Jose M. Alonso<sup>\*</sup>, Ehud Reiter<sup>†</sup>, Kees van Deemter<sup>†‡</sup>, Albert Gatt<sup>§</sup>

<sup>\*</sup> Centro Singular de Investigación en Tecnoloxías da Información (CiTIUS), Universidade de Santiago de Compostela  
alejandro.ramos@usc.es  
josemaria.alonso.moral@usc.es

<sup>†</sup> Department of Computing Science, University of Aberdeen  
alejandrosoto@abdn.ac.uk  
e.reiter@abdn.ac.uk  
k.vdeemter@abdn.ac.uk

<sup>‡</sup> Department of Information and Computing Sciences, Utrecht University  
k.vandeemter@uu.nl

<sup>§</sup> Institute of Linguistics and Language Technology, University of Malta  
albert.gatt@um.edu.mt

**Resumen**—Describimos una metodología para la construcción de modelos borrosos de expresiones geográficas sobre interpretaciones individuales de dichas expresiones por parte de expertos. Esta metodología aborda una tarea de modelado de lenguaje encuadrado dentro del desarrollo de un sistema *data-to-text* que generará descripciones textuales sobre mapas con información meteorológica en tiempo real. Para ello, recogimos datos proporcionados por meteorólogos en una encuesta y, sobre los mismos, creamos modelos borrosos consistentes que agregan las diferencias de interpretación de los expertos. Estos modelos permitirán generar expresiones de referencia geográfica sobre eventos meteorológicos georreferenciados, que formarán parte de los textos generados por el sistema *data-to-text* que desarrollaremos en un trabajo futuro.

**Términos clave**—vagueza, generación de lenguaje natural, conjuntos borrosos, modelado de lenguaje, sistemas de información geográfica, descripciones lingüísticas de datos

## I. INTRODUCCIÓN

La ingente cantidad de datos que se producen en todo tipo de ámbitos ha favorecido la aparición de varias disciplinas centradas en investigar cómo proporcionar a las personas la información relevante que permanece latente en dichos datos. Una de estas disciplinas es la generación de lenguaje natural (NLG), que estudia el problema de cómo generar textos a partir de datos, que puedan resultar útiles a lectores humanos [1], [2]. Dentro de este campo, los sistemas que generan textos a partir de datos no lingüísticos se conocen como *data-to-text* (D2T). En los últimos tiempos este tipo de sistemas gozan de cierta popularidad, gracias a su amplio uso comercial [2], [3] en una gran variedad de dominios.

Gran parte de los sistemas D2T proporcionan textos o informes que describen series de datos temporales, y ciertamente se pueden encontrar muchos ejemplos en el estado del arte, e.g., en predicción meteorológica [4]–[7], salud [8]–[10], o industria [11], entre muchos otros [1], [12]. Así mismo, también existen sistemas D2T que tratan datos caracterizados geográficamente, aunque su número es mucho más reducido respecto a los alimentados por series temporales de datos [13].

Una de las tareas esenciales en la concepción de un sistema D2T es el modelado del lenguaje, i.e., definir la semántica de los términos y expresiones a usar para describir los datos [14], [15]. Existen distintas formas de resolver esta tarea, tales como usar algoritmos heurísticos o de aprendizaje máquina sobre un

conjunto de *corpus* paralelo de texto y datos [16] para crear modelos de las expresiones de interés [17], conseguir que los expertos proporcionen dichos modelos, o recolectar datos de escritores o lectores que puedan ser usados para la aplicación de algoritmos de mapeado.

Por ejemplo, los sistemas D2T que generan textos a partir de series temporales de datos incluyen generalmente expresiones temporales para referirse a eventos o patrones relevantes encontrados en los datos. Realizar la tarea de modelado de lenguaje sobre expresiones temporales en este tipo de sistemas permite asegurarnos de que los textos generados incluyen términos cuyo significado se alinea con la interpretación de los expertos o las expectativas de los lectores, [17], [18]. Del mismo modo, disponer de un buen modelo geográfico en sistemas que generan textos sobre datos geográficos es esencial para generar expresiones que se refieran a localizaciones concretas y a regiones de interés.

Al mismo tiempo, es bastante frecuente que las expresiones temporales y geográficas que deben ser incluidas en los textos generados por sistemas D2T sean vagas, como “por la tarde” [4] o “áreas del suroeste” [19]. En situaciones donde la vagueza aparece (y con ella, casos fronterizos y conceptos graduales), se ha propuesto el uso de conjuntos borrosos para modelar expresiones lingüísticas en sistemas D2T [2], [20], [21]. Sin embargo, no existen sistemas de este tipo en el estado del arte que hagan uso de dichas técnicas, con la excepción de GALiWeather [5], que hace un uso básico de conjuntos borrosos para modelar expresiones temporales y cuantificadores.

En este contexto, este trabajo describe la metodología que hemos seguido para llevar a cabo una tarea de modelado de lenguaje de expresiones geográficas vagas. Esta tarea forma parte de un proyecto más amplio cuyo objetivo es la creación de un sistema D2T que genere descripciones textuales de mapas con información meteorológica en tiempo real. Nuestra aproximación se compone de una tarea de recogida de datos, proporcionados por expertos, y de un algoritmo heurístico que agrega dichos datos para crear modelos borrosos.

## II. TRABAJO RELACIONADO

El campo de NLG es amplio y existen gran cantidad de tipos de sistemas existentes con distintos propósitos como la gen-

eración de informes a partir de datos, creación de resúmenes a partir de distintas fuentes textuales, o generación de diálogo, narrativas e incluso poesía [1]. En nuestro caso, nos centramos en un problema muy específico, aquellos sistemas D2T cuyos datos de entrada están caracterizados geográficamente y cuyos textos a generar incluyen expresiones geográficas que se refieren a la ocurrencia de ciertos eventos registrados en los datos (e.g., “llovía en el norte de España”, “inundaciones en la Costa del Sol” o “vientos fuertes en el noroeste de Escocia”).

Aunque este tipo de referencias fueron introducidas hace décadas en los textos generados por el sistema FoG [6], RoadSafe es quizás el ejemplo más representativo y reciente de este tipo de sistemas [19], [22]. RoadSafe usaba datos de predicción meteorológica para generar predicciones textuales orientadas al mantenimiento de carreteras. Estos informes incluían expresiones temporales y geográficas para ayudar a identificar dónde y cuándo ciertos fenómenos relevantes tendrían lugar, con el objetivo de ayudar a los equipos de mantenimiento a mantener las condiciones de las vías afectadas en buen estado (ver ejemplos de dichas expresiones en Fig. 1). Así pues, desarrollar RoadSafe supuso también un estudio profundo de cómo generar buenas expresiones geográficas que se refiriesen de forma adecuada a la geografía subyacente a la información relevante extraída de los datos de entrada.

Concretamente, la aproximación de RoadSafe para modelar la generación de expresiones de referencia geográficas se basaba en técnicas estándar del campo de sistemas de información geográfica (GIS), en el que particionan la geografía subyacente de los eventos utilizando distintos esquemas, o *marcos de referencia* espaciales [23], que a su vez se componen de particiones no solapables (conocidas como *descriptores*). Por ejemplo, el marco de referencia *Dirección* se compone de los descriptores “nordeste”, “suroeste”, etc., y el marco “Proximidad Costera” se compone de los descriptores “costa” e “interior”.

Una vez que los límites numéricos de cada descriptor se definen para cada marco usando coordenadas de latitud-longitud, cada punto de datos puede ser caracterizado por un conjunto de descriptores (ej. “suroeste” y “costa”) y el generador de expresiones de referencia geográficas se encarga de seleccionar el mejor conjunto de descriptores que describan el área formada por el subconjunto de puntos que representan el evento.

En trabajos más recientes, el modelo geográfico utilizado en

Road surface temperatures will fall below zero **during the late evening and tonight** except in **areas below 100M**.

SW 10-25 gusts **this afternoon in southwestern areas**, veering WSW and increasing 15-35 after midnight, gusts 55-60 **during the evening and tonight** except in **areas above 500M**, increasing 20-45 then veering W **by early morning**, gusts 70-75 **tomorrow morning in most southern and central places**.

Wintery precipitation will affect most routes at first, falling as snow flurries **in some places above 300M** at first. Snow spreading **throughout the forecast period** to **all areas** and persisting **in some places above 300M** until end of period.

Fig. 1. Ejemplos de textos generados por RoadSafe [19]

RoadSafe fue ampliado mediante la inclusión de referencias espaciales de nombres propios, que según un estudio de varios conjuntos de *corpus* en distintos dominios, son las más predominantes [13]. Además, se plantea el desarrollo de un algoritmo de generación de expresiones de referencia geográficas que integre el marco de referencia de nombres propios con los ya existentes en RoadSafe. Por otro lado, en [24] se tratan las diferencias entre referencias absolutas y relativas y se proporciona un modelo basado en la mereología, en la que los descriptores de nombre propio se combinan con descriptores de otros marcos de referencia.

Las referencias descritas hasta el momento proporcionan buenas aproximaciones que permiten generar expresiones de referencia geográfica apropiadas sobre un conjunto de marcos de referencia. Sin embargo, en todos los casos los modelos descritos fueron desarrollados basados en un particionado nítido de la geografía a tratar. Tomar límites exactos entre descriptores geográficos puede considerarse una asunción poco intuitiva, especialmente si tenemos en cuenta cómo las personas entendemos y usamos incluso las referencias geográficas más simples como “norte” u “oeste”, en los que realmente las fronteras no suelen estar bien definidas, sino que son vagas. Por ejemplo, usando cualquiera de las aproximaciones anteriores, si una aldea se encuentra situada en la frontera entre dos descriptores, dependiendo de la granularidad espacial de nuestros datos es posible asignar descriptores opuestos (como “norte” y “sur”) a dos puntos dentro de la misma localidad.

Por ello, las limitaciones que en este sentido presentan los modelos descritos anteriormente suponen un fuerte incentivo a la hora de buscar otro tipo de aproximaciones que permitan modelar la imprecisión o la incerteza en el uso de referencias geográficas vagas. De hecho, el problema del tratamiento de la vaguedad en referencias geográficas no se limita únicamente a sistemas D2T, sino que existe una discusión más amplia dentro del ámbito de GIS, desde hace ya varias décadas [25]. En este sentido, la teoría de conjuntos borrosos ha sido aplicada en numerosos casos para tratar la vaguedad en conceptos geográficos y relaciones espaciales [26], [27].

Del mismo modo, como se ha descrito en la Sec. I, de una manera más general también se ha propuesto el uso de conjuntos borrosos en sistemas D2T para modelar términos vagos [2], [20], [21]. A día de hoy, el único sistema D2T desplegado en un entorno real que hace un uso básico de este tipo de técnicas es GALiWeather [5], si bien existe un número importante de casos de uso de aplicación de conjuntos borrosos para extracción de información lingüística (descripciones lingüísticas de datos), que en ocasiones se acompaña de generación textual basada en plantillas [2], [12].

### III. MOTIVACIÓN

Partiendo de las limitaciones que presentan los desarrollos previos de sistemas D2T que generan expresiones de referencia geográfica, la principal motivación de este trabajo es mejorar el modelado de conceptos geográficos vagos para fines de generación de lenguaje natural. Concretamente, nuestro objetivo es establecer una metodología de creación de modelos de



referencias geográficas vagas y de algoritmos de generación de expresiones de referencia sobre dichos modelos, basados en el uso de técnicas de conjuntos borrosos.

Puesto que D2T es un campo eminentemente aplicado, en el que los avances a nivel de investigación vienen dados por una necesidad real, en nuestro caso la metodología que proponemos se enmarca dentro del desarrollo de un sistema D2T para la generación de descripciones del estado meteorológico en tiempo real, sobre datos proporcionados por la Agencia de Meteorología de la Xunta de Galicia, MeteoGalicia [28]. Dichas descripciones incluirán expresiones de referencia geográfica que permitirán identificar fenómenos meteorológicos relevantes en el mapa, tales como temperatura, viento y estado del cielo.

En el marco del desarrollo del sistema D2T propuesto, este trabajo describe la tarea de modelado de lenguaje de las expresiones geográficas de interés a incluir en los textos generados por el sistema. Por otro lado, la metodología aquí descrita se basa en las ideas propuestas en [29] y [30], lo que permitirá consolidar nuevas formas de aplicar la teoría de conjuntos borrosos en sistemas D2T de forma práctica.

#### IV. RECOGIDA DE DATOS DE EXPERTOS

Aunque es corriente realizar el modelado de lenguaje partiendo de un conjunto paralelo de textos y datos, con el fin de analizar el significado de las palabras y expresiones a modelar, en nuestro caso este tipo de recurso no se encontraba disponible. Por un lado, no disponíamos de acceso a un conjunto de datos extenso (ej. predicciones textuales y datos de predicción) en los que realizar tal análisis. Por otro, nuestro plan es desarrollar un nuevo sistema D2T para proporcionar descripciones textuales de datos meteorológicos en tiempo real. Así pues, la aproximación que tomamos consistió en interactuar de forma directa con los expertos.

##### A. La encuesta

Dado que nuestro propósito es el modelado de expresiones geográficas, pedimos directamente al director del departa-



Fig. 2. Captura de pantalla de la encuesta realizada por los meteorólogos.

Marco de referencia		Descriptores
Dirección cardinal		Norte de Galicia, Sur de Galicia, Oeste de Galicia, Este de Galicia, Tercio norte, Extremo norte, Noroeste de Galicia, Noreste de Galicia, Suroeste de Galicia, Sureste de Galicia
Costa / Interior		Interior de Galicia
Nombre propio		Rías Baixas, Comarcas atlánticas
Mixto	Nombre y dirección	Oeste de A Coruña, Oeste de Ourense, Sur de Ourense, Sur de Lugo
	Nombre y costa	Litoral Atlántico, Litoral Cantábrico, Litoral norte, Interior de Coruña, Interior de Pontevedra
	Nombre y elevación	Áreas de montaña de Lugo, Áreas de montaña de Ourense

TABLA I  
LISTA DE REFERENCIAS GEOGRÁFICAS DE LA ENCUESTA.

mento de predicción de *MeteoGalicia* una lista con las expresiones geográficas más usadas por los meteorólogos a la hora de escribir predicciones textuales. Tomando esta lista como base, preparamos una encuesta web que fue distribuida entre los expertos de la agencia meteorológica. En dicha encuesta, se pidió a los participantes que, sobre un mapa de la región de Galicia (mostrada bajo una proyección *Mercator*), dibujasen un polígono que representase una referencia geográfica dada (ver la Figura 2).

En la encuesta se proporcionó a los participantes una lista de 24 descriptores, que aparecían en orden aleatorio. En esta lista, 20 de los 24 descriptores componen la lista original proporcionada por el director de predicción operativa, e incluyen direcciones cardinales, nombres propios y otro tipo de referencias como áreas montañosas, partes de provincias, etc. (ver la Tabla I para una taxonomía completa de los descriptores). Los restantes cuatro fueron añadidos para estudiar la combinación de direcciones cardinales mediante intersección (ej. explorar formas de combinar “norte” y “oeste” para obtener un modelo similar a “noroeste”), pero para nuestro propósito actual nos interesan sólo aquellos utilizados por los meteorólogos a la hora de escribir predicciones.

##### B. Resultados

La encuesta fue contestada por ocho expertos, obteniéndose 192 polígonos en total (160 sin considerar las intersecciones cardinales). A un nivel general, habíamos hipotetizado que los expertos serían bastante consistentes, dada su experiencia profesional. Así mismo, esperábamos también cierta variación entre las distintas respuestas.

Observamos que dichas hipótesis se han cumplido con claridad; los polígonos dibujados por los expertos se encuentran bastante concentrados y por tanto existe un gran acuerdo entre ellos. Por ejemplo, la Fig. 3 muestra una representación de las respuestas dadas por los meteorólogos para la dirección cardinal “oeste de Galicia” y un mapa de contornos que ilustra el porcentaje de respuestas que se solapan.

#### V. CREACIÓN DE DESCRIPTORES GEOGRÁFICOS BORROSOS

En la Figura 3, la gráfica de contornos puede tomarse como la base de la semántica de su expresión correspondiente,



Fig. 3. Representación gráfica de los polígonos dibujados por los expertos y gráfica de contornos para “oeste de Galicia”.

con una región nuclear que es aceptada por la mayoría, y un decaimiento gradual a medida que se avanza hacia la periferia exterior de las líneas de contorno. Así pues, en nuestro caso, la imprecisión surge de las diferencias interpersonales entre los meteorólogos.

Siguiendo esta noción, hemos creado modelos borrosos que agregan las opiniones de los expertos para cada descriptor. El método que usamos para esta tarea de modelado es una mejora del algoritmo heurístico descrito en [30], que producía modelos básicos basado en un muestreo de puntos y el conteo de intersecciones de polígonos, sin la inclusión de ninguna condición previa. Nuestro algoritmo va precedido además por un filtrado simple de los polígonos.

#### A. Filtrado de datos atípicos

Como comentamos anteriormente, los polígonos dibujados por los meteorólogos son muy consistentes visualmente, pero en algunos casos hemos observado pequeñas inconsistencias. Para mantener la elevada consistencia entre las respuestas obtenidas para los descriptores, aplicamos un filtrado simple de los trazados, consistente en descartar respuestas fuera del intervalo [media  $\pm$  2\*desviación típica] en términos de tamaño y localización del centroide.

#### B. Caracterización de un descriptor geográfico borroso

Usando los datos filtrados, pretendemos construir descriptores geográficos borrosos que sean simples y consistentes.

**Definition 1.** Descriptor geográfico borroso,  $G$ :

$$G = \{S, K, \mu_G\} \quad (1)$$

Formalmente, definimos un descriptor geográfico borroso  $G$  (ej. “sur de Galicia”) como un conjunto de 3 elementos: un área de soporte  $S$ , un área de núcleo  $K$ , y una función de pertenencia borrosa  $\mu_G$ , que evalúa el grado en el que un punto en un mapa ( $p = (x, y) \mid x, y \in \mathbb{R}$ ) puede considerarse parte de  $G$ :

$$\mu_G : \{\mathbb{R}, \mathbb{R}\} \rightarrow [0, 1] \quad (2)$$

Tomando  $\mu_G^1$  como base,  $K$  y  $S$  pueden definirse como:

$$K = \{p \mid \mu_G(p) = 1\} \quad (3)$$

$$S = \{p \mid \mu_G(p) > 0\} \quad (4)$$

Así pues,  $K$  es el conjunto de puntos (o región) cuyos grados de pertenencia son máximos con respecto a  $G$ , mientras que el soporte incluye a todos los puntos con un grado de pertenencia mayor que cero. Sin embargo, para la consecución de modelos consistentes, necesitamos aplicar las siguientes restricciones a  $G$ :

$$\forall G, K \subseteq S \quad (5)$$

$$\forall \{p_i, p_j\} \mid p_i, p_j \in S, p_i, p_j \notin K \text{ y } p_i \neq p_j \quad (6)$$

$$d(p_i, K) > d(p_j, K) \iff \mu_G(p_i) < \mu_G(p_j)$$

Estas condiciones aseguran que los modelos borrosos sean consistentes, al evitar la posibilidad de obtener  $K$ s y  $S$ s disjuntos, y asegurar la monotonicidad para  $\mu_G$ , donde  $d(p, K)$  es la distancia euclídea a  $K$  desde un punto  $p$  en  $S$ .

#### C. Construyendo descriptores sobre los datos de expertos

Un descriptor geográfico borroso  $G$ , como “norte de Galicia”, se modela de acuerdo con los polígonos dibujados por los expertos para dicha expresión. Formalmente, la colección de polígonos dibujados para un  $G$  específico se define como:

$$R_G = \{P_1, P_2, \dots, P_n\} \quad (7)$$

Cada  $P$  representa un polígono, y  $n$  es el número total de polígonos restantes tras el filtrado inicial. Cada polígono se compone de un conjunto de vértices, definidos bajo una proyección *plate carrée* (pares de valores de longitud y latitud).

La primera tarea para modelar un  $G$  dado consiste en determinar sus constituyentes ( $S$  y  $K$ ), puesto que calcular ambos nos permitirá caracterizar  $\mu_G$  posteriormente. Para ello, en primer lugar se transforman las coordenadas de los polígonos en  $R_G$  desde una proyección *plate carrée* a una proyección *Mercator*. A continuación, se define una malla de puntos equidistantes sobre ambos ejes cartesianos,  $D = (p_1, \dots, p_i, \dots, p_{|D|})$ , que se encuentra delimitada por la extensión máxima de la geografía subyacente (en nuestro caso, la región de Galicia). La distancia entre los puntos de la malla viene determinada por un parámetro  $\delta$ , que especifica un porcentaje de la extensión total del mapa. Por ejemplo,  $\delta = 1$  significa que la distancia entre un par de puntos de la malla contiguos es igual al 1% de la distancia entre límites opuestos del map sobre uno de los ejes.

Como se especifica en el Algoritmo 1, usando  $D$  y la colección de trazados expertos  $R_G$ , calculamos el número de veces que cada  $p$  en  $D$  está contenido en un polígono  $P$  en  $R_G$ , para determinar el porcentaje de polígonos que se solapan en un  $p$  dado. Basándonos en los porcentajes calculados para todos los puntos en  $D$ , determinamos  $K$  usando una aproximación de mayoría simple. Por tanto,  $PK$  está compuesto de

<sup>1</sup>Por simplicidad, nos referiremos a  $\mu_G(p)$  en vez de  $\mu_G(x, y)$ .


**Algorithm 1** Cálculo de  $K$  y  $S$  para un descriptor  $G$ 


---

**Entrada:**  $D, R_G$   
**Salida:**  $K, S$

- 1:  $PCS \leftarrow ()$
- 2: **for all**  $p_i \in D$  **do**
- 3:      $count \leftarrow 0$
- 4:     **for all**  $P_j \in R_G$  **do**
- 5:         **if**  $p_i \in P_j$  **then**
- 6:              $count \leftarrow count + 1$
- 7:         **end if**
- 8:     **end for**
- 9:      $pcs_i \leftarrow count / |R_G|$
- 10:  $PCS \leftarrow PCS \cup pcs_i$
- 11: **end for**
- 12:  $PK \leftarrow \{p_i \in D \mid pcs_i > 0.5\}$
- 13:  $PS \leftarrow \{p_i \in D \mid pcs_i > 0\}$
- 14:  $K \leftarrow ConvexHull(PK)$
- 15:  $S \leftarrow ConvexHull(PS)$
- 16:  $bp \leftarrow \operatorname{argmax}_{p_i \in S}(d(p_i, K))$
- 17:  $op \leftarrow \operatorname{argmin}_{p_i \in D \text{ y } p_i \notin S}(d(p_i, bp))$
- 18:  $od \leftarrow d(K, op)$
- 19: **return**  $K, S, od$

---

aquellos puntos cuyos porcentajes son  $> 50\%$ , y  $PS$  cubre todos los puntos donde el porcentaje es  $> 0\%$ . En vez de considerar  $S$  y  $K$  como colecciones de puntos en  $D$  (lo que  $PK$  y  $PS$  son), calculamos sus envolventes convexas, esto es, los polígonos convexas que delimitan sus áreas. Este proceso elimina cualquier área disjunta perteneciente a  $K$  que pueda aparecer por divergencias entre los polígonos dibujados, ya que el envolvente las agrega bajo una única área. Finalmente, calculamos  $od$ , la suma de la distancia del vértice de  $S$  más lejano a  $K$  ( $bp$ ) y la distancia mínima de ese punto a otro externo a  $S$  ( $op$ ), que será usada en la definición de  $\mu_G$ , junto con  $K$  y  $S$ .

#### D. Evaluación de un descriptor geográfico borroso

Tomando como base los tres elementos devueltos por el Algoritmo 1, la función  $\mu_G$  que evalúa un punto  $p$  se define como:

$$\mu_G(p) = \begin{cases} 1 & \text{si } p \in K \\ 1 - d(p, K)/od & \text{si } p \in S \text{ y } p \notin K \\ 0 & \text{si } p \notin S \end{cases} \quad (8)$$

La función de pertenencia  $\mu_G$  se define siguiendo la condición de monotonicidad. Bajo dicha definición, todos los puntos en  $S$  tienen grados de pertenencia  $> 0$  y este grado decrece a medida que el punto evaluado se aleja de  $K$ . En estas condiciones, la caracterización de un descriptor geográfico borroso  $G$  mediante la definición de su soporte y su núcleo nos permite crear modelos simples que son consistentes y fáciles de interpretar.

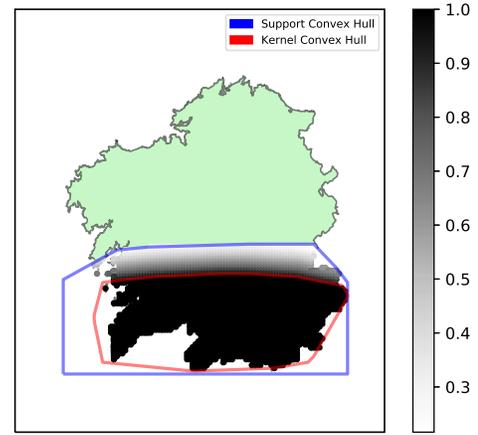


Fig. 4. Representación gráfica del descriptor geográfico borroso “Sur de Galicia”.

#### E. Ejemplos

Con el fin de ilustrar los resultados del algoritmo de modelado y explicar algunas de las decisiones integradas en el Algoritmo 1 y en la definición de  $\mu_G$ , describimos a continuación dos modelos borrosos distintos que resultan de la agregación de los polígonos dibujados por los meteorólogos para dos expresiones geográficas bajo distintas categorías o marcos de referencia en la Tabla I.

El primer descriptor, mostrado en la Figura 4, modela la expresión “sur de Galicia”. Este modelo puede considerarse muy regular, tanto para  $K$  como para  $S$ . La condición de mayoría simple asegura además un mayor consenso a la hora de definir el significado de “sur”. Este descriptor proporciona un área extensa en el que los puntos interiores pueden considerarse como parte del “sur de Galicia” en distintos grados.

Otros descriptores adoptan distintas formas, donde  $S$  varía en ancho respecto a  $K$ . Este es el caso, por ejemplo de “áreas de montaña de Lugo”. Como muestra la Figura 5, la forma de este descriptor es en cierto modo elipsoidal y la distancia

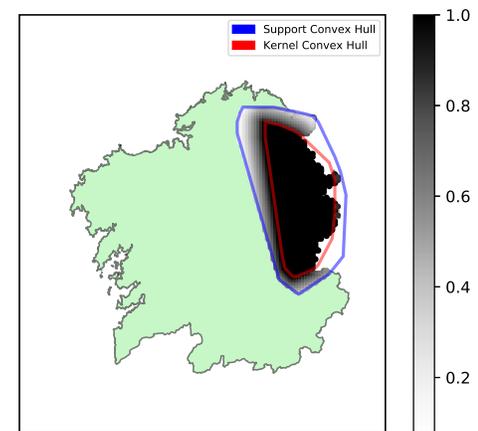


Fig. 5. Representación gráfica del descriptor geográfico borroso “Áreas montañosas de Lugo”.

entre los límites de  $S$  y  $K$  no es constante, comparada con la Figura 4. Este caso ilustra bien cómo algunos puntos en  $S$  más cercanos a su periferia tienen grados de pertenencia más elevados que otros más lejanos, debido a su cercanía a  $K$ .

## VI. CONCLUSIONES

En este trabajo hemos descrito una metodología basada en la aplicación de conjuntos borrosos para la realización de una tarea de modelado de lenguaje, en el contexto del desarrollo de un sistema D2T que generará descripciones meteorológicas georreferenciadas. Esta metodología incluye la recogida de datos expertos sobre referencias geográficas y su agregación mediante la construcción de descriptores borrosos. Como trabajo futuro, desarrollaremos un algoritmo de generación de expresiones de referencia geográficas que utilice los descriptores descritos en este trabajo, que constituirá además el núcleo del sistema D2T.

## AGRADECIMIENTOS

A. Ramos-Soto es investigador postdoctoral financiado por la “Consellería de Cultura, Educación e Ordenación Universitaria” (481B 2017/030) y J.M. Alonso es Investigador Ramón y Cajal (RYC-2016-19802). Además, este trabajo está parcialmente financiado por los proyectos TIN2017-90773-REDT (iGLN), TIN2017-84796-C2-1-R (BIGBISC), TIN2014-56633-C3-1-R (BAI4SOW) y TIN2014-56633-C3-3-R (ABS4SOW) cofinanciados por el “Ministerio de Economía y Competitividad.” También reconocemos el apoyo de la Xunta de Galicia (Centro singular de investigación de Galicia acreditación 2016-2019) y la Unión Europea (Fondo FEDER - European Regional Development Fund - ERDF).

## REFERENCIAS

- [1] A. Gatt and E. Kraemer, “Survey of the state of the art in natural language generation: Core tasks, applications and evaluation,” *Journal of Artificial Intelligence Research*, vol. 61, pp. 65–170, 2018.
- [2] A. Ramos-Soto, A. Bugarín, and S. Barro, “On the role of linguistic descriptions of data in the building of natural language generation systems,” *Fuzzy Sets and Systems*, vol. 285, pp. 31–51, 2016.
- [3] Gartner, “Neural Networks and Modern BI Platforms Will Evolve Data and Analytics,” <http://www.gartner.com/smarterwithgartner/neural-networks-and-modern-bi-platforms-will-evolve-data-and-analytics/>, accessed: 2017-03-14.
- [4] S. Sripada, E. Reiter, and I. Davy, “Sumtime-mousam: Configurable marine weather forecast generator,” *Expert Update*, vol. 6, no. 3, pp. 4–10, 2003.
- [5] A. Ramos-Soto, A. Bugarín, S. Barro, and J. Taboada, “Linguistic descriptions for automatic generation of textual short-term weather forecasts on real prediction data,” *Fuzzy Systems, IEEE Transactions on*, vol. 23, no. 1, pp. 44–57, Feb 2015.
- [6] E. Goldberg, N. Driedger, and R. Kittredge, “Using natural-language processing to produce weather forecasts,” *IEEE Expert*, vol. 9, no. 2, pp. 45–53, 1994.
- [7] J. Coch, “Interactive generation and knowledge administration in multi-meteo,” in *Proceedings of the Ninth International Workshop on Natural Language Generation, Niagara-on-the-lake, Ontario, Canada, 1998*, pp. 300–303, software demonstration.
- [8] J. Hunter, Y. Freer, A. Gatt, E. Reiter, S. Sripada, and C. Sykes, “Automatic generation of natural language nursing shift summaries in neonatal intensive care: Bt-nurse,” *Artificial Intelligence in Medicine*, vol. 56, no. 3, pp. 157 – 172, 2012.
- [9] E. Reiter, R. Robertson, and L. Osman, “Types of knowledge required to personalise smoking cessation letters,” in *Artificial Intelligence and Medicine: Proceedings of AIMDM-1999*, W. Horn, Ed. Berlin, New York: Springer, 1999, pp. 398–399.
- [10] A. Goldstein and Y. Shahar, “An automated knowledge-based textual summarization system for longitudinal, multivariate clinical data,” *Journal of biomedical informatics*, vol. 61, pp. 159–175, 2016.
- [11] J. Yu, E. Reiter, J. Hunter, and S. Sripada, “Sumtime-turbine: A knowledge-based system to communicate gas turbine time-series data,” in *Developments in Applied Artificial Intelligence*, ser. Lecture Notes in Computer Science, P. Chung, C. Hinde, and M. Ali, Eds. Springer Berlin Heidelberg, 2003, vol. 2718, pp. 379–384.
- [12] N. Marin and D. Sánchez, “On generating linguistic descriptions of time series,” *Fuzzy Sets and Systems*, vol. 285, pp. 6 – 30, 2016, special Issue on Linguistic Description of Time Series.
- [13] R. de Oliveira, Y. Sripada, and E. Reiter, *Proceedings of the 15th European Workshop on Natural Language Generation (ENLG)*. Association for Computational Linguistics, 2015, ch. Designing an Algorithm for Generating Named Spatial References, pp. 127–135.
- [14] D. Roy and E. Reiter, “Connecting language to the world,” *Artificial Intelligence*, vol. 167, no. 1-2, pp. 1–12, 2005.
- [15] E. Reiter, “An architecture for data-to-text systems,” in *Proceedings of the 11th European Workshop on Natural Language Generation*, S. Busemann, Ed., 2007, pp. 97–104.
- [16] J. Novikova, O. Dušek, and V. Rieser, “The E2E dataset: New challenges for end-to-end generation,” in *Proceedings of the 18th Annual Meeting of the Special Interest Group on Discourse and Dialogue*, Saarbrücken, Germany, 2017, arXiv:1706.09254. [Online]. Available: <https://arxiv.org/abs/1706.09254>
- [17] E. Reiter, S. Sripada, J. Hunter, and I. Davy, “Choosing words in computer-generated weather forecasts,” *Artificial Intelligence*, vol. 167, pp. 137–169, 2005.
- [18] E. Reiter and S. Sripada, “Should corpora texts be gold standards for nlg?” in *Proceedings of the International Natural Language Generation Conference*, 2002, pp. 97–104.
- [19] R. Turner, S. Sripada, E. Reiter, and I. P. Davy, “Selecting the content of textual descriptions of geographically located events in spatio-temporal weather data,” *Applications and Innovations in Intelligent Systems*, vol. XV, pp. 75–88, 2007.
- [20] J. Kacprzyk, “Computing with words is an implementable paradigm: Fuzzy queries, linguistic data summaries, and natural-language generation,” *IEEE Trans. Fuzzy Systems*, pp. 451–472, 2010.
- [21] A. Ramos-Soto, A. Bugarín, and S. Barro, “Fuzzy sets across the natural language generation pipeline,” *Progress in Artificial Intelligence*, pp. 1–16, 2016.
- [22] R. Turner, S. Sripada, E. Reiter, and I. P. D. Davy, “Using spatial reference frames to generate grounded textual summaries of georeferenced data,” in *Proceedings of the 2008 International Conference on Natural Language Generation (INLG08)*, Salt Fork, Ohio, 12-14 June 2008.
- [23] S. C. Levinson, *Space in language and cognition: Explorations in cognitive diversity*. Cambridge University Press, 2003, vol. 5.
- [24] R. de Oliveira, S. Sripada, and E. Reiter, “Absolute and relative properties in geographic referring expressions,” in *Proceedings of the 9th International Natural Language Generation conference*, 2016, pp. 256–264.
- [25] P. Fisher, “Sorites paradox and vague geographies,” *Fuzzy sets and systems*, vol. 113, no. 1, pp. 7–18, 2000.
- [26] V. B. Robinson, “A perspective on the fundamentals of fuzzy sets and their use in geographic information systems,” *Transactions in GIS*, vol. 7, no. 1, pp. 3–30, 2003.
- [27] P. Fisher, A. Comber, and R. Wadsworth, “Approaches to uncertainty in spatial data,” *Fundamentals of spatial data quality*, pp. 43–59, 2006.
- [28] Meteogalicia, “Meteogalicia’s web site.” <http://www.meteogalicia.es>, 2018.
- [29] A. Ramos-Soto, N. Tintarev, R. de Oliveira, E. Reiter, and K. van Deemter, “Natural language generation and fuzzy sets: An exploratory study on geographical referring expression generation,” in *IEEE World Congress on Computational Intelligence, 2016 IEEE International Conference on Fuzzy Systems*, 2016.
- [30] A. Ramos-Soto, J. M. Alonso, E. Reiter, K. van Deemter, and A. Gatt, “An empirical approach for modeling fuzzy geographical descriptors,” in *Fuzzy Systems (FUZZ-IEEE), 2017 IEEE International Conference on*. IEEE, 2017, pp. 1–6.



# Indistinguibilidad y Modelado de Tamaño en Sistemas *Data-to-text*

Nicolás Marín, Gustavo Rivas-Gervilla y Daniel Sánchez,  
 Departamento de Ciencias de la Computación e Inteligencia Artificial  
 Universidad de Granada, 18071 Granada, España  
 Email: {nicm, griger, daniel}@decsai.ugr.es

**Abstract**—En este trabajo extendemos nuestra propuesta previa de modelado de tamaño en base al contexto, incluyendo el tratamiento de la indistinguibilidad en la percepción del tamaño. Ilustramos la importancia de este aspecto con una experimentación que, adicionalmente, muestra una forma de determinar experimentalmente los parámetros del método.

**Index Terms**—Tamaño, modelado difuso, descripción lingüística de datos, sistemas *data-to-text*

## I. INTRODUCCIÓN

El lenguaje natural es una herramienta cada vez más imprescindible en el desarrollo de interfaces de comunicación hombre-máquina amigables. Prueba de ello es la importancia, cada vez más marcada, de la investigación en el ámbito de Generación de Lenguaje Natural, en general, y en el ámbito de los sistemas *data-to-text* en particular. Este tipo de sistemas tienen como objetivo elaborar información textual a partir del análisis de datos [1]. Particularmente, se pretende que dichos textos sean similares a los que escribiría un experto humano.

Uno de los problemas más importantes en este ámbito es determinar la semántica de los términos lingüísticos empleados en los textos, así como el grado de correspondencia entre dichos términos y los datos. Dado que dichos términos suelen representar conceptos difusos, es natural considerar conjuntos difusos como modelos de dicha semántica [2]–[5]. Estos conjuntos difieren de los conjuntos clásicos (o *crisp*) en que cada elemento del dominio pertenece al conjunto con un grado en el intervalo  $[0, 1]$ . La función que asocia a cada elemento este grado se denomina función de pertenencia. Uno de los usos más importantes de estos términos es la identificación de objetos en un conjunto, para lo cual se utilizan *expresiones de referencia*, que son sintagmas nominales formados habitualmente por una conjunción de términos que expresan propiedades de los objetos.

En [6] hemos propuesto un enfoque para la determinación de las funciones de pertenencia que modelan la semántica de conceptos difusos relativos al tamaño. Dicha propuesta considera funciones que son dependientes y condicionadas por el contexto de la aplicación donde se van a usar los términos lingüísticos.

Este trabajo ha sido financiado en parte por el Gobierno de España y el Fondo Europeo de Desarrollo Regional - FEDER a través del proyecto TIN2014-58227-P. Así como por la beca del Ministerio de Educación, Cultura y Deporte de España, FPU16/05199. Corresponding author: G. Rivas-Gervilla.

En este trabajo avanzamos un paso más en nuestra propuesta incluyendo en la misma el tratamiento de la indistinguibilidad. Este problema surge debido a que las computadoras son capaces de almacenar información sobre los objetos (sobre su tamaño en este caso) de manera más precisa de lo que nosotros somos capaces de percibir visualmente, lo cual afecta a nuestro método.

En la siguiente sección describimos la importancia del contexto en el modelado de términos relativos al tamaño y resumimos la propuesta presentada en [6]. En la sección III describimos el problema de la indistinguibilidad y cómo afecta a nuestro método, y detallamos los cambios en la misma que nos permitirán adaptarnos al grado de indistinguibilidad del tamaño de los objetos en un contexto concreto. En la sección IV se presenta un experimento con usuarios para ilustrar nuestra discusión. En esa misma sección se muestra una posible forma de determinar experimentalmente uno de los parámetros clave en nuestra propuesta. Finalmente, las dos últimas secciones contienen una breve discusión de los resultados y las conclusiones de nuestro trabajo, respectivamente.

## II. MODELADO DEL TAMAÑO

### A. Modelado y contexto

Como ya hemos indicado, uno de los aspectos clave en el desarrollo de sistemas *data-to-text* es la definición de la semántica de los términos lingüísticos que se van a emplear en los textos generados. En el caso particular de conceptos relativos a propiedades de los objetos, dicha semántica debe establecer una correspondencia entre características y valores de los datos asociados a dichos objetos y el cumplimiento de la propiedad. En el caso particular de propiedades difusas (como puede ser el tamaño, ya que un objeto puede ser grande en un cierto grado), este objetivo se cumple mediante la definición de las funciones de pertenencia asociadas a dichos conceptos difusos, como es bien conocido. Determinar las funciones de pertenencia es uno de los problemas clave en el uso de conjuntos difusos en éste y otros dominios de aplicación.

Sin embargo, la determinación de la función de pertenencia no plantea únicamente el problema de cómo obtener la asignación de grados a elementos de un referencial. En muchas ocasiones ocurre que la función de pertenencia no es única, sino que depende del contexto de aplicación (datos concretos, usuario, objetivos, etc.). Es decir, la definición de la función de pertenencia es relativa al contexto.

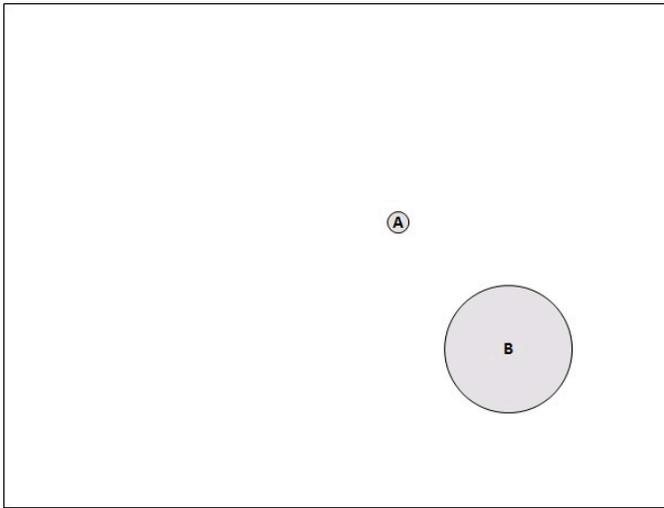


Fig. 1. Escena con objetos A y B

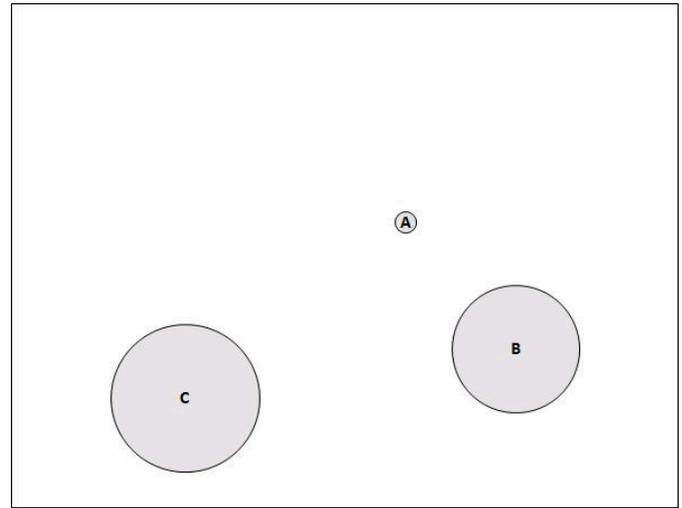


Fig. 2. Escena con objetos A, B y C

Para ilustrar esta situación en el contexto de sistemas *data-to-text*, vamos a considerar el ejemplo de las Figuras 1 y 2, extraído de [6]. En la escena de la Figura 1, para referirnos al objeto B es suficiente decir *el objeto grande*. Sin embargo, en la escena de la Figura 2, que contiene los mismos objetos de la Figura 1 más un objeto adicional, la referencia *el objeto grande* no llevaría a un usuario hipotético a señalar el objeto B, sino el C. Es decir, el contexto (en este caso, la aparición de nuevos datos, concretamente el objeto C) hace que el cumplimiento de la propiedad “tamaño” cambie, particularmente porque el rango de valores de tamaño que consideramos ha cambiado con la aparición de un nuevo tamaño (el tamaño de C). En este caso, el objeto B pasa a encajar mejor con la etiqueta *mediano*, siendo por tanto más adecuado en la Figura 2 referirse a B como *el objeto mediano* de cara a conseguir que un hipotético usuario lo identifique correctamente. Por lo tanto, queda claro que la definición de las funciones de pertenencia para las etiquetas *grande* y *mediano* es dependiente del contexto, por lo que fijar un conjunto de funciones de pertenencia independiente del contexto a priori no nos permite interactuar correctamente con el usuario en la mayoría de los casos, como demostramos en [6].

### B. Una propuesta de modelado basada en contexto

En [6] aportamos una primera aproximación a la solución de este problema. La propuesta consiste en determinar las funciones de pertenencia para las etiquetas *grande*, *mediano* y *pequeño* asociadas a la propiedad “tamaño” de forma dependiente del contexto asociado a los datos, teniendo en cuenta los distintos tamaños precisos de los objetos presentes en el conjunto de datos/escena. Asumiendo que el conjunto de tamaños es  $S = \{s_1, \dots, s_n\}$ ,  $n > 1$ , con  $s_i \in \mathbb{R}^+$  y  $0 < s_1 \leq \dots \leq s_n \forall 1 \leq i \leq n$ , la propuesta puede resumirse como sigue:

- En primer lugar, determinamos los tamaños que van a ser totalmente representativos de cada una de las eti-

quetas consideradas, es decir, van a tener grado 1 de pertenencia a las mismas. De manera natural establecemos por definición  $pequeño(s_1) = grande(s_n) = 1$  y  $pequeño(s_n) = grande(s_1) = mediano(s_1) = mediano(s_n) = 0$ . Nótese que esta definición es independiente de los valores concretos de  $s_1$  y  $s_n$ , así como de la diferencia  $|s_1 - s_n|$  entre ambos (volveremos sobre este último punto más adelante, puesto que es una de las motivaciones del presente trabajo). En el caso  $n > 2$  tendremos también representantes de la propiedad *mediano*. Si  $n$  es impar hay un único representante:  $s' = s'' = s_{(\lceil n/2 \rceil)}$ . En caso contrario tenemos dos representantes:  $s' = s_{(n/2)}$  y  $s'' = s_{(n/2+1)}$ . Para todo representante  $s \in \{s', s''\}$  de mediano tenemos  $mediano(s) = 1$  y  $pequeño(s) = grande(s) = 0$  por definición.

- El grado de pertenencia a las tres etiquetas de los tamaños en  $S$  que no son representativos de ninguna de ellas se determina mediante un proceso de *clustering*, centrado en los valores representativos de cada etiqueta, y en base a las distancias de dichos tamaños con respecto a los representativos. Como método de *clustering* empleamos el método definido en [7] en base a representaciones por niveles [8]. Este método toma como punto de partida una relación difusa reflexiva y simétrica de semejanza en el conjunto de tamaños  $S$ . En el caso particular de los tamaños, esta relación se obtiene en base a las distancias a través de un parámetro  $d_m$  que define la máxima distancia a la que pueden estar dos valores para que su semejanza sea mayor que 0. Sean  $s_i, s_j \in S$  y sea  $d(s_i, s_j) = |s_i - s_j|$  la distancia Euclídea entre ellos. La semejanza entre  $s_i$  y  $s_j$  en base al parámetro  $d_m$ ,  $R^{d_m}(s_i, s_j)$ , se calcula mediante la siguiente expresión:

$$R^{d_m}(s_i, s_j) = \max \left\{ 1 - \frac{d(s_i, s_j)}{d_m}, 0 \right\} \quad (1)$$



Como se demuestra en [6], para garantizar las condiciones que hemos expuesto anteriormente sobre los grados de pertenencia de  $s_1$ ,  $s'$ ,  $s''$  y  $s_n$  a las tres etiquetas de tamaño, es suficiente con elegir un  $d_m$  que satisfaga las siguientes condiciones:

- En el caso  $n = 2$  se requiere  $d_m \leq s_n - s_1$ .
- En el caso  $n > 2$  se requiere  $0 < d_m \leq \min(d(s_1, s'), d(s'', s_n))$ . Esta condición implica asimismo  $d_m \leq s_n - s_1$  en este caso.

A partir de una relación de semejanza difusa como ésta, el proceso de *clustering* basado en representación por niveles se basa en la realización de un *clustering crisp* en los diferentes niveles  $\Lambda(R^{d_m}) = \{R^{d_m}(s_i, s_j) \mid s_i, s_j \in S\} \setminus \{0\}$ . Este conjunto es finito,  $\Lambda(R^{d_m}) = \{\alpha_1, \dots, \alpha_k\}$  con  $k \geq 1$  y  $1 = \alpha_1 > \dots > \alpha_{k+1} = 0$ . Para cada  $\alpha_k \in \Lambda(R^{d_m})$  puede obtenerse un *clustering crisp* basado en recubrimientos de  $S$  de la siguiente forma:

- 1) Calcular el  $\alpha_k$ -corte de  $R^{d_m}$ , que es una relación *crisp* reflexiva y simétrica.
- 2) Calcular el *clustering* de  $S$  a nivel  $\alpha_k$  como el conjunto de cliques maximales del  $\alpha_k$ -corte de  $R^{d_m}$ . Sea  $C_{\alpha_k} \subset \{0, 1\}^S$  el conjunto de *clusters* obtenidos, cada uno de ellos asociado biunívocamente a un clique maximal. Nótese que estos *clusters* pueden solaparse, formando un recubrimiento de  $S$ .

Como consecuencia de las restricciones impuestas sobre  $d_m$  se da  $R^{d_m}(s_1, s_n) = 0$  para todo  $d_m$  que las cumpla, y por tanto  $|C_{\alpha_k}| \geq 2$ , dado que  $s_1$  y  $s_n$  estarán siempre en distintos *clusters*. Además es fácil demostrar que existe un solo *cluster*  $C_{\alpha_k}^p \in C_{\alpha_k}$ , verificando  $s_1 \in C_{\alpha_k}^p$ , y un solo *cluster*  $C_{\alpha_k}^g \in C_{\alpha_k}$ , cumpliéndose  $s_n \in C_{\alpha_k}^g$ , siendo como ya hemos comentado  $C_{\alpha_k}^p \neq C_{\alpha_k}^g$ . Además, en el caso  $n > 2$  definimos:

$$C_{\alpha_k}^m = \bigcup \{C_{\alpha_k}^i \mid C_{\alpha_k}^i \cap \{s', s''\} \neq \emptyset\} \quad (2)$$

Es decir,  $C_{\alpha_k}^m$  es la unión de todos los *clusters* que contienen al menos a uno de los representantes de la categoría *mediano*. Nótese que  $C_{\alpha_k}^m$  puede ser vacío, algo que ocurre en todos los niveles particularmente cuando  $n = 2$ .

A partir del *clustering* en cada nivel, los *clusters* difusos que modelan las funciones de pertenencia para las tres propiedades *pequeño*, *mediano* y *grande* se obtienen, siguiendo las ideas expuestas en [7], [8], como sigue:  $\forall s_i \in S$ ,

$$\text{pequeño}(s_i) = \sum_{\alpha_k \mid s_i \in C_{\alpha_k}^p} (\alpha_k - \alpha_{k+1}) \quad (3)$$

$$\text{mediano}(s_i) = \sum_{\alpha_k \mid s_i \in C_{\alpha_k}^m} (\alpha_k - \alpha_{k+1}) \quad (4)$$

$$\text{grande}(s_i) = \sum_{\alpha_k \mid s_i \in C_{\alpha_k}^g} (\alpha_k - \alpha_{k+1}) \quad (5)$$

$\alpha_k$	$C_{\alpha_k}^p$	$C_{\alpha_k}^m$	$C_{\alpha_k}^g$
1	{10}	{25}	{40}
2/3	{10}	{20, 25, 30}	{40}
1/3	{10, 20}	{20, 25, 30}	{30, 40}

TABLE I  
Clusters crisp POR NIVELES PARA  $d_m = 15$ .

Como ejemplo, sea  $S = \{10, 20, 25, 30, 40\}$  ( $n = 5$ ). En este contexto tenemos que  $s_1 = 10$  es el tamaño representativo para *pequeño*,  $s_5 = 40$  para *grande*, y  $s_3 = 25$  es el (único) representante para *mediano*. Sea  $d_m = 15$ , que es el máximo valor posible en este ejemplo. Dado que el conjunto de distancias entre tamaños es  $\{0, 5, 10, 15, 20, 30\}$  tenemos que  $\Lambda(R^{15}) = \{1, 2/3, 1/3\}$ . La Tabla I muestra los *clusters crisp* en cada nivel. En base a esta información y las Ecuaciones (3)-(5), se tiene finalmente:

$$\begin{aligned} \text{pequeño} &= 1/10 + (1/3)/20 \\ \text{mediano} &= (2/3)/20 + 1/25 + (2/3)/30 \\ \text{grande} &= (1/3)/30 + 1/40 \end{aligned}$$

### III. INDISTINGUIBILIDAD Y MODELADO

#### A. Influencia de la indistinguibilidad

Uno de los grandes problemas en la interacción con datos a través de las computadoras es lo que se denomina *hueco semántico*<sup>1</sup>. La principal forma en que se manifiesta este problema es que, mientras que los ordenadores almacenan datos descritos mediante valores de variables en dominios que suelen ser muy precisos y contener muchos valores distintos (por ejemplo, mediante números reales), los seres humanos solemos utilizar información descrita en base a conceptos expresados de forma lingüística. Hemos podido ver distintos ejemplos claros de esta diferencia en las secciones anteriores: mientras que para el ordenador el tamaño de un objeto se describe mediante un valor real numérico, los seres humanos utilizamos términos lingüísticos como *grande*, etc. Cada uno de estos términos se corresponde con un grupo o intervalo de valores precisos, grupo o intervalo que suele tener una frontera imprecisa, y por tanto una forma adecuada de modelar dicha correspondencia es mediante el uso de conjuntos difusos, como hemos visto y es bien conocido en nuestro ámbito.

Sin embargo, existe un problema adicional asociado al *hueco semántico* que recibe menos atención en la literatura, y que tiene que ver con la distinguibilidad. Este problema es típico en, aunque no exclusivo de, aplicaciones que involucran la percepción humana, como lo es el problema del tamaño que nos ocupa en este trabajo, y puede expresarse de manera informal como sigue: el ser humano no es capaz de percibir diferencias en el valor de propiedades de objetos al mismo nivel que una computadora.

Podemos ilustrar el problema que supone la indistinguibilidad para nuestro método de modelado sensible al contexto con

<sup>1</sup>Del inglés *semantic gap*.

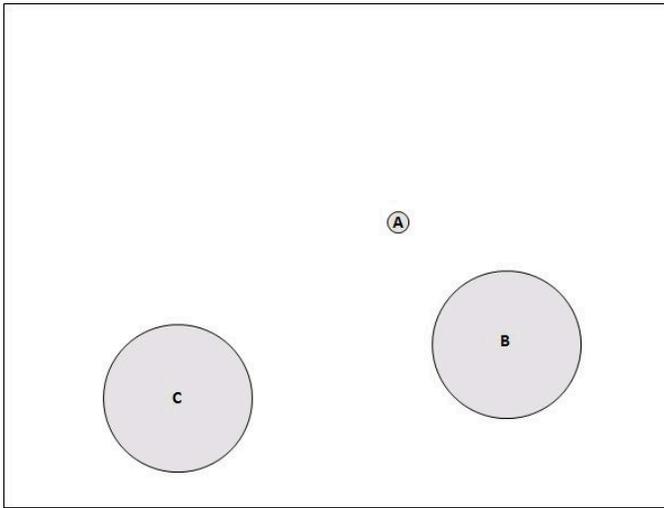


Fig. 3. Modificación de la escena de la Figura 2: tamaño del objeto B distinto pero indistinguible del tamaño del objeto C

un ejemplo. Consideremos la escena de la Figura 3, que se ha obtenido a partir de la escena de la Figura 2 aumentando el tamaño del objeto B hasta ser indistinguible (pero no igual) del tamaño del objeto C. En este caso, dado que para una computadora los tamaños de C y B son distintos, nuestro método diría que el objeto B es *mediano* con grado 1, mientras que los objetos A y C son medianos con grado 0. En base a este modelado sensible al contexto, un algoritmo de generación de expresiones de referencia propondría *el objeto mediano* como una forma de identificar claramente al objeto B. Sin embargo, al ser los tamaños de B y C indistinguibles visualmente para el usuario, éste no tendría claro a cuál de los dos objetos (B ó C) estamos haciendo referencia con dicha expresión (dado que A es claramente el pequeño en este caso).

Para solventar este problema es necesario modificar nuestra propuesta para tener en cuenta la distinguibilidad de objetos. Para ello vamos a considerar las siguientes hipótesis:

- Es posible determinar un umbral de distancia  $d_s$  tal que los tamaños  $s_i$  y  $s_j$  son distinguibles si, y solo si,  $d(s_i, s_j) > d_s$ .
- El umbral  $d_s$  puede ser sensible a distintos aspectos del contexto, tales como distancia entre los objetos, etc. Más adelante prestaremos atención a este problema.

En la siguiente sección detallamos la modificación que proponemos a nuestro método de modelado sensible al contexto para resolver el problema de la indistinguibilidad de objetos.

### B. Método propuesto

Nuestra propuesta consta de los siguientes pasos:

- 1) Determinación del umbral de distinguibilidad  $d_s$  adecuado para el modelado en el contexto concreto de aplicación. Es posible obtener  $d_s$  de distintas formas. En la Sección IV veremos un sencillo ejemplo de obtención de  $d_s$  de forma experimental bajo ciertos supuestos. El



Fig. 4. Ejemplo de pregunta del cuestionario.

estudio y propuesta de otras técnicas se plantea como trabajo futuro.

- 2) Determinación del umbral de similitud  $d_m$  para el contexto concreto de aplicación, teniendo en cuenta el valor de  $d_s$  en dicho contexto. Es importante determinar  $d_m$  después de  $d_s$  dado que el valor de este último afecta a las condiciones que se imponen sobre  $d_m$ . En primer lugar, por la semántica de ambos umbrales, es evidente que debe cumplirse  $d_s < d_m$ , dado que dos tamaños son indistinguibles cuando la distancia entre los mismos está por debajo de  $d_s$ , mientras que son absolutamente diferentes cuando la distancia está por encima de  $d_m$ . Pero además, el valor de  $d_s$  afecta a la forma en que se obtiene  $d_m$ , dado que, como hemos visto, este último viene restringido por condiciones que tienen que ver con la distancia entre objetos representativos de cada una de las etiquetas para los cuales, tras la discusión y el ejemplo que hemos visto en la sección anterior, debemos exigir que sean distinguibles. Más concretamente:

- Si  $s_1$  y  $s_n$  son indistinguibles entonces no podemos modelar tamaños de forma sensible al contexto.
- Supongamos  $s_1$  y  $s_n$  distinguibles y sea  $S_m \subset S$  el subconjunto de tamaños que son distinguibles tanto de  $s_1$  como de  $s_n$  (obviamente  $s_1, s_n \notin S_m$ ). Entonces:
  - Si  $S_m = \emptyset$  solo podemos modelar dos tamaños, *pequeño* y *grande*, siendo sus representantes  $s_1$  y  $s_n$ , respectivamente.
  - Si  $S_m \neq \emptyset$  entonces podemos modelar también *mediano*, siendo su(s) representante(s) el valor o valores centrales de  $S_m$  (dependiendo de que  $S_m$  tenga un número impar o par de valores).

Una vez determinados los representantes de las etiquetas se seleccionará un valor de  $d_m$  adecuado que cumpla con los requisitos ya expuestos anteriormente:  $d_m \leq s_n - s_1$  para dos etiquetas, y  $0 < d_m \leq$



$\min(d(s_1, s'), d(s'', s_n))$  para las tres.

- 3) Aplicar nuestra técnica de *clustering* para determinar las funciones de pertenencia para las tres etiquetas. Para ello utilizaremos una relación de semejanza que introduce una modificación con respecto a la de la Ecuación (1), dado que queremos que cuando la distancia entre dos tamaños sea menor o igual a  $d_s$ , su semejanza sea 1. La nueva relación de semejanza viene dada por

$$R^{d_m}(s_i, s_j) = \begin{cases} 1 & d(s_i, s_j) \leq d_s \\ 1 - \frac{d(s_i, s_j)}{d_m} & d_s < d(s_i, s_j) < d_m \\ 0 & d_m \leq d(s_i, s_j) \end{cases} \quad (6)$$

Es fácil demostrar que cuando  $d_s = 0$  (lo cual implica que todo par de tamaños distintos son distinguibles), nuestra propuesta se reduce a la propuesta expuesta en la Sección II-B.

#### IV. EJEMPLO DE APLICACIÓN

Para ilustrar la influencia de la indistinguibilidad y su dependencia del contexto se ha realizado una sencilla experimentación. Concretamente, se ha elaborado una encuesta con diferentes escenas en las que cada escena consta de dos objetos de distinto tamaño a una distancia determinada. Al usuario se le pregunta que identifique el más pequeño de los dos, permitiéndole elegir entre tres respuestas posibles: *el que está a la derecha, el que está a la izquierda y no sabría decirte*. La figura 4 muestra un ejemplo de escena de la encuesta (aparece marcada la respuesta correcta).

Para elaborar el conjunto de escenas de la encuesta, se ha trabajado con tres granos de tamaño  $C < B < A$  (elegidos en los extremos y centro del referencial), con cinco niveles de distancia (0, 0.3, 0.5, 0.7 y 1), también relativos, y configurando ejemplos en el que el ratio de parecido en tamaño va desde 0.95 hasta 0.995. La experimentación se ha realizado en la misma computadora con seis usuarios distintos a los que se les presenta el mismo conjunto de escenas con orden aleatorio.

El objetivo de la encuesta es señalar la posible dependencia del contexto de la indistinguibilidad, comprobando la variabilidad de respuestas entre usuarios, tamaños y distancias, e ilustrar una forma experimental para fijar el umbral  $d_s$  para una configuración de contexto dada.

##### A. Resultados

La tabla II muestra, para cada pareja distancia/grano de tamaño, los umbrales de ratio entre tamaños a partir de los cuales se ha obtenido una respuesta distinta de la correcta. Se resalta en negrita el valor mínimo obtenido en cada columna. Las distancias se muestran en valor relativo, representando el 1 la máxima distancia utilizada y el 0 la mínima distancia utilizada.

La figura 5 ilustra los datos de la tabla de manera gráfica. Como se puede observar, en la experimentación realizada, conforme descende el tamaño, en general, baja también el umbral, es decir, el usuario necesita una mayor distancia en

TABLE II  
UMBRALES AGREGANDO CON EL MÍNIMO

Distancia (rel.)	Tamaño		
	A	B	C
1	<b>98</b>	98,5	<b>95</b>
0,7	98,5	98,5	96
0,5	98	<b>98</b>	95
0,3	98	98,5	97
0	98,5	98	96

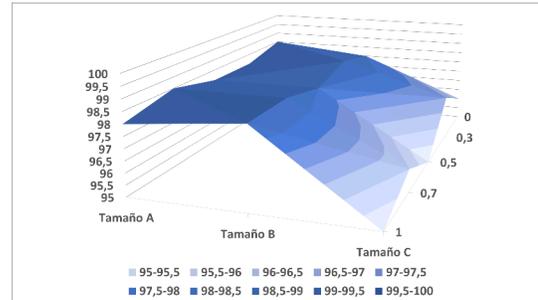


Fig. 5. Umbrales por tamaño y distancia, agregando con el mínimo.

tamaño relativo para acertar. No se aprecia dicha tendencia en el caso de la distancia. Los mismos datos, agregando los valores de umbral obtenidos en cada usuario con una media en lugar de con el mínimo, se muestran en la tabla III.

La figura 6 ilustra los datos de la tabla de manera gráfica. Se observan similares tendencias, pero menos acusadas, dado que la media limita el efecto de los usuarios con menor precisión en la percepción del tamaño.

Por último, se muestran los datos de dos usuarios a título de ejemplo. La tabla IV y la figura 7, muestran los datos de un usuario con alta precisión en la percepción del tamaño, mientras que la tabla V y la figura 8 muestran los datos de un usuario con menor precisión.

#### V. DISCUSIÓN

A la vista de la anterior experimentación, se pone de manifiesto que la *indistinguibilidad* es un elemento variable altamente dependiente del contexto. Por tanto, es importante que el sistema de generación de expresiones de referencia sea capaz de ajustar su funcionamiento a la capacidad de distinguibilidad propia del contexto en el que se ejecuta.

La experimentación que hemos desarrollado aquí, aunque simple, sirve para ilustrar que el ajuste de la indistinguibilidad es complejo. Nótese que la experimentación realizada utiliza solo tres variables para caracterizar el contexto, a saber, el *usuario*, el *tamaño* del objeto y la *distancia* entre ellos. El resto de variables se fijan: el *tipo* de objeto, el *color*, la *posición* en la pantalla, el *dispositivo*, ... por enumerar solo algunas variables de una lista que puede ser muy extensa dependiendo del sistema y del tipo de escenas con las que trabaje. Por citar solo un ejemplo, piénsese que se varía el color de los objetos: es bien conocido por todos que el color influye en la percepción del tamaño de los objetos.

TABLE III  
 UMBRALES AGREGANDO CON LA MEDIA

Distancia (rel.)	Tamaño		
	A	B	C
1	<b>98,7</b>	99,1	98,0
0,7	99,2	99,3	<b>97,8</b>
0,5	99,2	<b>99,0</b>	97,8
0,3	98,7	99,3	98,5
0	99,2	99,0	98,1

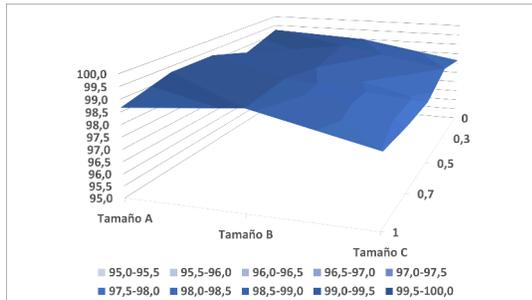


Fig. 6. Umbrales por tamaño y distancia, agregando con la media.

Por tanto, un sistema de generación de expresiones de referencia será mejor cuanto mayor sea el ajuste al contexto que tiene en cuenta para producir sus expresiones.

## VI. CONCLUSIONES

Una de las contribuciones más reconocidas de la Teoría de Conjuntos Difusos en el ámbito de los sistemas *data-to-text* es el modelado de propiedades difusas. Este trabajo contribuye a facilitar dicha tarea proponiendo una metodología para determinar de forma automática la semántica de propiedades difusas en base al contexto y teniendo en cuenta la distinguibilidad de las propiedades de los objetos, que es uno de los problemas más arduos que surgen en este tipo de sistemas.

## REFERENCES

- [1] E. Reiter and R. Dale, *Building Natural Language Generation Systems*. Cambridge, UK: Cambridge University Press, 2000.
- [2] N. Marín and D. Sánchez, "On generating linguistic descriptions of time series," *Fuzzy Sets and Systems*, vol. 285, pp. 6–30, 2016.
- [3] A. Ramos-Soto, A. Bugarín, and S. Barro, "On the role of linguistic descriptions of data in the building of natural language generation systems," *Fuzzy Sets and Systems*, vol. 285, pp. 31–51, 2016.
- [4] K. van Deemter, *Not Exactly: In Praise of Vagueness*. New York, NY, USA: Oxford University Press, Inc., 2012.
- [5] A. Gatt, N. Marín, F. Portet, and D. Sánchez, "The role of graduality for referring expression generation in visual scenes," in *Proceedings IPMU 2016, Part I, CCIS 610*, J. Carvalho, M.-J. Lesot, U. Kaymak, S. Vieira, B. Bouchon-Meunier, and R. R. Yager, Eds. Springer, 2016, pp. 191–203.
- [6] N. Marín, G. Rivas-Gervilla, and D. Sánchez, "An approximation to context-aware size modeling for referring expression generation," in *IEEE International Conference on Fuzzy Systems, FUZZ-IEEE*, 2018.
- [7] D. Dubois and D. Sanchez, "Fuzzy Clustering based on Coverings," in *Towards Advanced Data Analysis by Combining Soft Computing and Statistics*, ser. Studies in Fuzziness and Soft Computing, C. Borgelt, M. A. Gil, J. M. C. Sousa, and M. Verleysen, Eds. Springer, 2013, vol. 285, pp. 319–330.
- [8] D. Sánchez, M. Delgado, M. Vila, and J. Chamorro-Martínez, "On a non-nested level-based representation of fuzziness," *Fuzzy Sets and Systems*, vol. 192, pp. 159–175, 2012.

 TABLE IV  
 UMBRALES PARA USUARIO CON ALTA PRECISIÓN EN LA PERCEPCIÓN DEL TAMAÑO

Distancia (rel.)	Tamaño		
	A	B	C
1	<b>98,7</b>	99,1	98,0
0,7	99,2	99,3	<b>97,8</b>
0,5	99,2	<b>99,0</b>	97,8
0,3	98,7	99,3	98,5
0	99,2	99,0	98,1

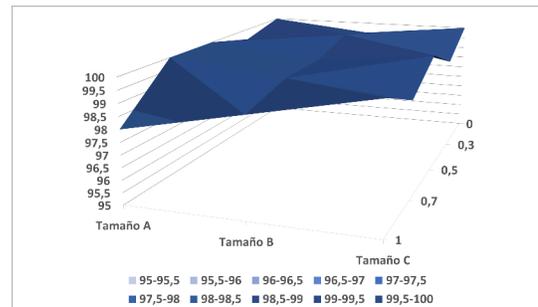


Fig. 7. Umbrales para usuario con alta precisión en la percepción del tamaño.

 TABLE V  
 UMBRALES PARA USUARIO CON MENOR PRECISIÓN EN LA PERCEPCIÓN DEL TAMAÑO

Distancia (rel.)	Tamaño		
	A	B	C
1	<b>98,7</b>	99,1	98,0
0,7	99,2	99,3	<b>97,8</b>
0,5	99,2	<b>99,0</b>	97,8
0,3	98,7	99,3	98,5
0	99,2	99,0	98,1

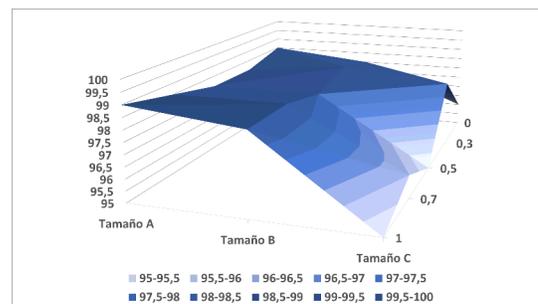


Fig. 8. Umbrales para usuario con menor precisión en la percepción del tamaño.



# Método para medir la credibilidad de los agentes en videojuegos empleando Descripción Lingüística de Fenómenos Complejos y su aplicación como herramienta de apoyo en el proceso de enseñanza-aprendizaje en un curso de Inteligencia Artificial \*†‡

Clemente Rubio-Manzano, Tomás Lermenda, Alejandra Segura, Claudia Martínez-Araneda y Christian Vidal  
SOMOS Research Group - Universidad del Bío-Bío & MCIS Research Group - Universidad de Cádiz

## Resumen

El objetivo de este trabajo es proponer un nuevo método para medir la credibilidad de los agentes artificiales que actúan en un mundo virtual empleando la Descripción Lingüística de Fenómenos Complejos y las Funciones de Equivalencia Restringidas. La combinación de ambas técnicas computacionales permite generar y comparar informes de comportamiento en lenguaje natural generados automáticamente. Con el fin de mostrar y explorar las posibilidades de este nuevo método, se desarrolló una aplicación web que puede emplearse como herramienta de apoyo a la docencia de Inteligencia Artificial y donde cada alumno puede evaluar por sí mismo la calidad de su implementación en los respectivos proyectos.

**Palabras Clave:** Inteligencia Artificial, Videojuegos, Descripción Lingüística de Datos, Funciones de Equivalencia Restringidas, Lógica Difusa.

## I. Introducción

La Inteligencia Artificial (IA) tiene como objetivo lograr que una máquina tenga una inteligencia similar a la humana [7]. Sin embargo, históricamente, han coexistido dos visiones (IA fuerte e IA débil) que se corresponden con las siguientes definiciones dadas por Marvin Minsky y John McCarthy, respectivamente: “IA es la ciencia de

*crear máquinas capaces de realizar tareas que requerirían inteligencia si las tuviera que hacer un humano*”; “IA es la ciencia y la ingeniería de crear máquinas inteligentes”. Como se indica en [7]: “Todos los avances logrados hasta ahora en el campo de la IA son manifestaciones de la IA débil”, es decir, dotar a las máquinas de la capacidad de realizar tareas específicas mejor que las personas se puede realizar con éxito, incluso, una IA específica puede superar a la pericia humana.

Por otro lado, un aspecto fundamental en el campo de la IA es determinar si las máquinas son realmente inteligentes, entonces dicha evaluación dependerá de la visión de IA que se tenga. En el caso de la IA fuerte, Alan Turing propuso su famoso test para determinar si un computador exhibía inteligencia humana. En el caso de la IA débil se optó por chequear si las máquinas realizan correctamente las tareas para las cuales fueron diseñadas y programadas.

La IA débil se ha aplicado con éxito en numerosas disciplinas. En el ámbito de los videojuegos, la IA se centra en crear entidades software (creadas mediante algoritmos/programas de computador que actúan sobre un entorno virtual) que produzcan en el espectador la ilusión de inteligencia. Por otro lado, se ha comprobado que los agentes (también llamados NPCs, por sus siglas en inglés Non-player Characters, o Bots) más divertidos y “jugables” son aquellos que se comportan como los jugadores humanos [13]. Surge así el desafío de tratar de desarrollar NPCs que posean un buen grado de imitación y, al mismo tiempo, diseñar e implementar instrumentos que permitan medirlo y evaluarlo [6]. No solo se trata en evaluar que un NPC realice las tareas específicas como un jugador humano, además, queremos que la IA se parezca a la IA del jugador humano lo más posible, debe ser creíble, cuanto más, mejor.

Esta característica se conoce como “credibilidad” (“believability”) y habitualmente se evalúa empleando una extensión el mencionado Test de Turing [5]: “Supongamos que estamos jugando e interactuamos con algún agente, ¿se podría distinguir observándolo al agente si es un

\* Clemente Rubio-Manzano. Departamento de Matemáticas, Universidad de Cádiz, España

† Clemente Rubio-Manzano, Tomás Lermenda, Christian Vidal y Alejandra Segura, Departamento de Sistemas de Información, Universidad del Bío-Bío, Chile

‡ Claudia Martínez-Araneda. Departamento de Ingeniería Informática, Universidad Católica Santísima Concepción, Chile

*jugador humano o un bot? Si no se puede distinguir, entonces se considera que el bot ha pasado el test* ". Esta prueba se diseñó para evaluar las habilidades de los bots para suplantar a un jugador humano.

El test anterior se puede considerar una evaluación basada en el chequeo visual de una determinada funcionalidad. Este hecho tiene como principal limitación a la subjetividad del proceso porque la observación visual es una tarea compleja al requerir procesar una gran cantidad de información generada durante las partidas. Incluso, cabe la posibilidad, de pérdida información debido a la rapidez de ejecución de los algoritmos de IA.

Nuestro trabajo consiste en enriquecer estos test alternativos para reducir la subjetividad mediante la captura de todos los datos posibles generados durante las partidas y entregar automáticamente un conjunto de descripciones lingüísticas en lenguaje natural que proporcionen información sobre el comportamiento de los agentes. Para ello, emplearemos la Descripción Lingüística de Fenómenos Complejos (DLFC)[14] y las Funciones de Equivalencia Restringidas (REFs, de sus siglas en inglés) [1]. En este sentido, el "comportamiento de un agente" está relacionado directamente con el comportamiento del algoritmo IA elegido para su implementación, en este caso, algoritmos de búsqueda en un espacio de estados.

La estructura del trabajo es como sigue, en la Sección II se realiza una introducción desde el punto de vista del proceso de enseñanza-aprendizaje al ser éste el fin último de su aplicación. La Sección III detalla un método para medir la credibilidad de los agentes implementados y comparar el comportamiento de los jugadores humanos con los agentes. Posteriormente, en la Sección IV se explica la experimentación y la evaluación implementadas sobre los proyectos de los estudiantes. Finalmente, la Sección de conclusiones y trabajo futuro proporciona algunos comentarios finales sobre el presente trabajo y el futuro del mismo.

## II. Motivación

Desde el año 2011 se ha implementado una nueva metodología de enseñanza-aprendizaje basada en videojuegos en el curso de IA de la Universidad del Bío-Bío (Chile). Su objetivo es proporcionar a los estudiantes una herramienta de ayuda en el proceso de comprensión de los diferentes algoritmos heurísticos que se enseñan en las clases de teoría.

En particular, en el año 2017, el proyecto consistió en desarrollar un videojuego cuyo agente protagonista tenía que capturar un conjunto de recompensas (que proporcionan energía) distribuidas por el escenario. El agente, que pierde energía cada cinco segundos, debía mantenerse en el escenario durante el mayor tiempo posible sin agotar

energía. Tres agentes adversarios (también programados por los estudiantes) tratarán de robarle la energía, en el caso de que ésta se agote la partida termina.

En este contexto, un agente (y su algoritmo de comportamiento asociado) está correctamente implementado cuando es capaz de imitar a un jugador experto humano (ver sección III) . El proceso de evaluación consiste en chequear la calidad de la imitación desde dos puntos de vista: visualmente, observando el comportamiento del agente artificial en una partida; formalmente, analizando el código del proyecto del alumno. Este proceso tiene algunas limitaciones:

- 1) Tiempo excesivo que se requiere para chequear de forma visual la funcionalidad de los proyectos. Se podría convertir en un problema cuando el número de estudiantes es alto y hay un único profesor.
- 2) Tarea compleja debido a la dificultad de evaluar un gran número parámetros importantes en el proyecto: cantidad (memoria utilizada, iteraciones realizadas, estructuras de datos usadas) y calidad (como es la IA, es decir, que habilidad tiene a la hora de realizar ciertas acciones)
- 3) Se pueden perder numerosos detalles en la inspección visual al transcurrir las partidas muy rápidamente: el depurador genera mucha información que es difícil de entender; gran cantidad de datos que se generan en la ejecución.
- 4) Imposibilidad (dificultad) de realizar una evaluación individual

Para superar estas limitaciones se propone incorporar la DLFC al proceso de enseñanza-aprendizaje de la asignatura IA y, en particular, a su evaluación basada en proyectos. Utilizando DLFC los estudiantes pueden obtener retroalimentación inmediata, técnica y personalizada sobre los fallos cometidos durante el desarrollo de sus proyectos y conseguir más información sobre todos los detalles de ejecución de los algoritmos heurísticos empleados para programar los agentes inteligentes. En la literatura, existen trabajos que han estudiado la aplicación de la DLFC (y en la algunos casos de la Descripción Lingüística de Datos-LDD) al proceso de enseñanza-aprendizaje [9], [3], [2] y [12].

Por otro lado, esta propuesta es muy beneficiosa para los profesores ya que les permitirá:

- Ahorrar tiempo al permitirles centrarse en otros aspectos a evaluar lo que implicará un mejor entendimiento de la implementación de los algoritmos.
- Mejorar el proceso clásico de evaluación proporcionando retroalimentación personalizada a los estudiantes.
- Apoyar el desarrollo individual de proyectos al permitir un seguimiento más cercano y la oportunidad



de centrarse en los aspectos más debilidades de los estudiantes.

Con el fin de mostrar y explorar las posibilidades de esta herramienta se ha desarrollado una plataforma web y se ha incorporado al proceso de enseñanza aprendizaje de la asignatura. Ahora cada estudiante puede obtener, en tiempo real, retroalimentación sobre su proyecto, además establecer su propio plan de aprendizaje. Adicionalmente, los perfiles de comportamiento para tales agentes y jugadores humanos se pueden utilizar para medir la calidad de las IA mediante una adaptación del test Turing al contexto de los videojuegos.

### III. Un método para medir la credibilidad de los agentes y compararlo con jugadores humanos

En esta sección se presenta un método para medir la credibilidad de los agentes basado en cuatro pasos.

#### Paso 1. Generación de la traza de ejecución.

Se ha empleado una traza de ejecución para capturar y almacenar los datos generados a partir de los movimientos de los humanos, agentes y oponentes. Una traza de ejecución es una técnica empleada habitualmente para capturar y almacenar los valores de las estructuras de datos empleadas en una aplicación. Se emplea, también, como herramienta de depuración y análisis del rendimiento.

Concretamente, la traza de ejecución implica la detección y almacenamiento de eventos relevantes durante la ejecución de un programa para posteriormente realizar un análisis más detallado. En particular, empleamos las trazas de ejecución para almacenar los valores de las métricas a partir de los cuales se pueden analizar el comportamiento de las entidades. Las métricas son las siguientes:

- Distancia entre jugador ( $P$ ) y adversarios ( $O$ ) calculada a partir de sus posiciones.
- Distancia entre jugador, adversarios y la recompensa más cercana ( $R^*$ ) calculada a partir de sus posiciones.
- Tiempo en llegar a la recompensa.
- Energía del jugador en cada momento.
- Memoria ocupada e iteraciones realizadas.

#### Paso 2. Definición de la red de percepciones computacionales

Ampliamos la red de percepciones computacionales presentada en [10]. En este caso, la energía, memoria ocupada e iteraciones realizadas se incorporan como nuevas variables. Se extiende la red, reglas y las plantillas de generación de lenguaje natural para soportar los nuevos requisitos.

Las variables lingüísticas se definen a partir de las métricas establecidas previamente. Mediante la agregación de los términos lingüísticos que componen cada una de las variables se definen las reglas de comportamiento. Por ejemplo, la percepción computacional (CP, de sus siglas en inglés) de situación ( $CP_{Situation}$ ) quedaría definida de la siguiente forma:

$$CP_{Situation} = CP_{Protection}(P, O), CP_{Distance}(P, O), CP_{Energy}(P).$$

Esta ecuación establece que la CP de situación se calcula en función de la protección, la distancia entre el jugador-oponente y la energía del jugador. Los valores correspondientes para esta CP se calculan usando las siguientes reglas:

Consecuente (Situación)	Antecedente (Protección, Distancia, Energía)
Risky	Intermediate, Close, Normal
Dangerous	Low, Close, Normal
Safe	Intermediate, Normal, Normal
Easy	Low, Normal, Normal
Dangerous	Low, Normal, Low
Dangerous	Normal, Close, Low
Dangerous	Normal, Normal, Low

El resto de CPs se definen de forma análoga:

- $CP_{Attitude} = CP_{Distance}(P, R^*), CP_{Distance}(O, R^*)$
- $CP_{Movement} = CP_{Distance}(P, R^*), CP_{Distance}(P, O), CP_{Energy}(P)$
- $CP_{Ability} = CP_{Attitude}, CP_{Movement}, CP_{Time}$
- $CP_{Skill} = CP_{Attitude}, CP_{Movement}, CP_{Situation}$
- $CP_{Resources} = CP_{Iterations}, CP_{Memory}$

#### Paso 3. Generación automática de los perfiles de comportamiento.

En cada periodo de tiempo (habitualmente cada segundo) se calculan los valores para cada una de las CPs instantáneas. Con el fin de agruparlas y resumirlas se emplea el concepto de CP Resumen, denotada por  $\Sigma CP$  y definida como  $\Sigma CP = ((a_1, w_1), \dots, (a_n, w_n))$ . El objetivo de cada  $\Sigma CP$  es sintetizar en un vector lingüístico difuso el resultado global obtenido tras la partida para una CP. En nuestro caso, este tipo de CP nos permite obtener el número de veces que un valor  $(a_1, \dots, a_n)$  ocurrió durante la partida.

Estos tipos de CP nos proporcionan un conjunto de variables, su valor asociado y el grado  $\alpha$ , que indica la media difusa para un valor determinado. Por ejemplo, un valor para la CP de Situación podría ser *Safe* con un grado de 0.8 en un instante  $i$ ,  $X = Safe$  con 0.7 en un instante  $i + 1$ , y etc. Por tanto, al final de la ejecución, tendremos que  $a_i$  (en el ejemplo “safe”) se ha dado  $N$  veces con  $M$  grados diferentes  $\beta_1, \dots, \beta_m$  (por supuesto, algunos de

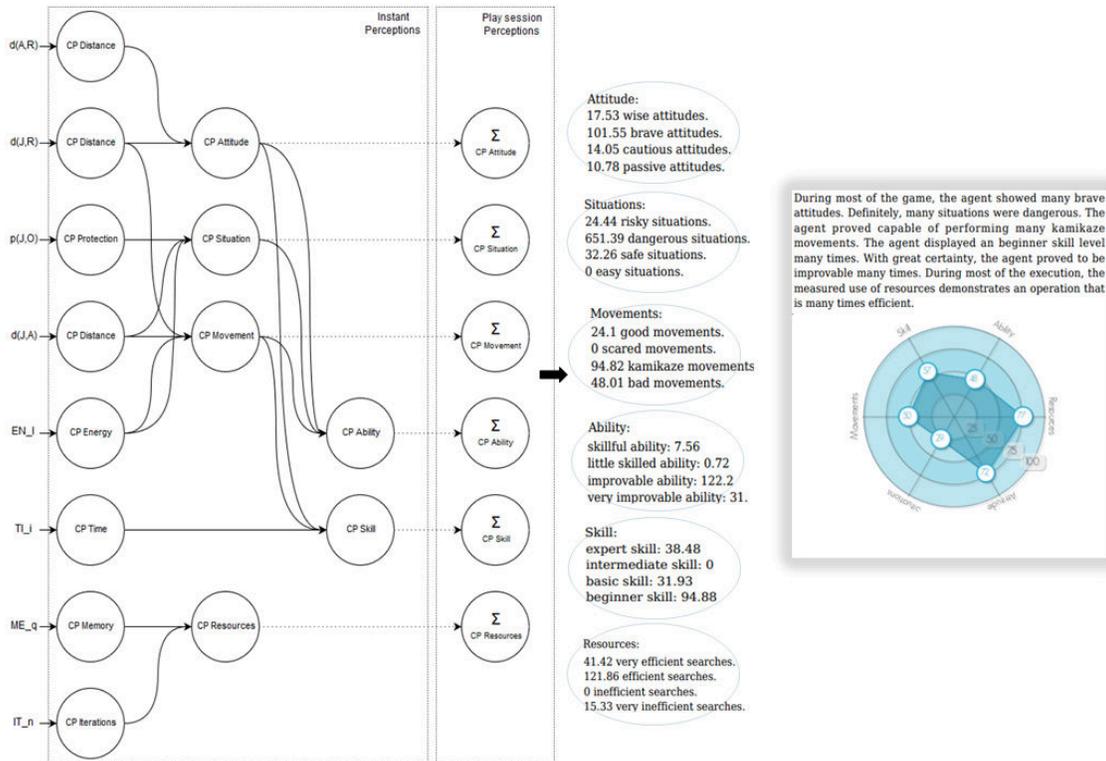


Fig. 1. Generación automática de informe de comportamiento a partir de los valores capturados en la traza de ejecución

estos grados podrían ser iguales). El grado final se calcula como sigue:  $\alpha_i = ((\beta_1 + \dots + \beta_n)/N)$ .

Por ejemplo, los siguientes resúmenes pueden obtenerse a partir de diferentes  $\Sigma CP$  (ver Figura 1). La generación del perfil de comportamiento se realiza empleando el conjunto de  $\Sigma CP$ . Para cada CP se crea una descripción lingüística en función del par  $(a_i, w_i) \in \Sigma CP$ . Los porcentajes se calculan para cada  $\Sigma CP$ . El porcentaje  $p_i$  se transforma en un término lingüístico de cantidad como sigue: "few" cuando  $p_i \in [0, 1/3]$ ; "several" cuando  $p_i \in [1/3, 2/3]$  o "many" cuando  $p_i \in [2/3, 1]$ . Entonces, vamos a considerar cuatro casos:

- 1) Existe un par  $(a_i, p_i) \in \Sigma CP$  cuyo  $p_i$  es mayor o igual a 66 por ciento.
- 2) Existe un par  $(a_i, p_i) \in \Sigma CP$  cuyo  $p_i$  es mayor o igual a 33 por ciento.
- 3) Existe dos pares  $(a_1, p_1), (a_2, p_2) \in \Sigma CP$  cuyos  $p_i$  son mayor o igual a 33 por ciento.
- 4) No existe ningún par  $(a_i, p_i) \in \Sigma CP$  cuyos  $p_i$  son mayor a 33 por ciento.

Y generar las siguientes descripciones en función de ellos. Mostramos aquí la tabla de CP de situación. El informe completo se puede ver en la Figura 2.

Casos	Descripción Lingüística
1	Definitely, <i>degree</i> situations were <i>value</i>
2	<i>degree</i> situations were <i>value</i>
3	<i>degree</i> situations were <i>value</i> <sub>1</sub> , although <i>degree</i> situation also were <i>value</i> <sub>2</sub>
4	Diverse situations were detected during the most part of the play session

#### Paso 4. Método para comparar perfiles de comportamiento entre jugadores humanos y agentes.

Como se ha mencionado en la introducción, uno de los objetivos más importantes en IA en el ámbito de los videojuegos es crear agentes que imiten la habilidad de un jugador humano. Por lo tanto, debemos definir la referencia de mejor jugador humano analizando las partidas y obteniendo un perfil de comportamiento referencia. Tras este proceso se obtuvo que:

- La actitud del jugador es valiente durante la mayor parte de la partida;
- Las situaciones por las que pasa son principalmente seguras;
- Los movimientos realizados son principalmente buenos;
- Se obtiene que es experto y hábil con un uso eficiente de tiempo y espacio.

Ahora, se puede proceder a la comparación de los mismos



mediante la definición de una medida de similitud basada en las funciones de equivalencia restringidas (REFs) entre las CPs Resumen obtenidas para cada caso.

**Definición 3.1:** Una REF,  $f$ , es una correspondencia  $[0, 1]^2 \rightarrow [0, 1]$  que satisface las siguientes condiciones:

- 1)  $f(x, y) = f(y, x)$  para todo  $x, y \in [0, 1]$
- 2)  $f(x, y) = 1$  si y sólo si  $x = y$
- 3)  $f(x, y) = 0$  si y sólo si  $x = 1$  y  $y = 0$  o  $x = 0$  y  $y = 1$
- 4)  $f(x, y) = f(c(x), c(y))$  para todo  $x, y \in [0, 1]$ ,  $c$  siendo una negación fuerte.
- 5) Para todo  $x, y, z \in [0, 1]$ , si  $x \leq y \leq z$ , entonces  $f(x, y) \geq f(x, z)$  and  $f(y, z) \geq f(x, z)$

Por ejemplo,  $g(x, y) = 1 - |x - y|$  satisface las condiciones (1)-(5) con  $c(x) = 1 - x$  para todo  $x \in [0, 1]$ . Una medida de similitud basada en REFs entre dos términos lingüísticos para ampliar el motor de inferencia del lenguaje Bousi Prolog se propuso en [11].

Un algoritmo de IA, usado para implementar un agente, tiene un comportamiento cercano al jugador humano cuando sus respectivos perfiles de comportamiento son similares. La puntuación final (de 1 a 7) se calcula mediante una medida de similitud para cada CP. La ecuación para calcular el grado de credibilidad es la siguiente:

$$FG = G_{Min} + S(Actitud) + S(Situacin) + S(Movimiento) + S(Habilidad) + S(Competencia) + S(Eficiencia)$$

$G_{Min} = 1$  punto (mínimo puntuación que un alumno en la Universidad del Bío-Bío puede obtener). Donde  $S(Attitude) = S_{REF}(\Sigma CP_{Attitude}^{Human}, \Sigma CP_{Attitude}^{Bot})$  es la similitud entre la actitud del jugador humano y la actitud del agente. El resto de relaciones de similitud se definen de forma análoga. La siguiente definición formaliza esta media:

**Definición 3.2:** Dadas dos percepciones computacionales  $\Sigma CP_i$ ,  $\Sigma CP_j$  cuyos vectores de porcentajes lingüísticos son  $\{(a_1, p_1) \dots, (a_n, p_n)\}$  y  $\{(b_1, q_1) \dots, (b_n, q_n)\}$  respectivamente. Una medida de similitud entre  $\Sigma CP_i$  y  $\Sigma CP_j$  se define como

$$S_{REF}(\Sigma CP_i, \Sigma CP_j) = \sum_{i=0}^n (REF(p_i, q_i)) / n$$

siendo  $REF(p_i, q_i) = 1 - |p_i - q_i|$

Por ejemplo, dadas dos CP Resumen  $CP_{Actitud}^{Humano}$ ,  $CP_{Actitud}^{Agente}$ , entonces  $\Sigma CP_{Actitud}^{Humano} = \{(wise, 122.35), (brave, 289), (cautious, 87.59), (passive, 8.75)\}$  y  $\Sigma CP_{Actitud}^{Agente} = \{(wise, 17.53), (brave, 101.55), (cautious, 14.05), (passive, 10.78)\}$ . Entonces el vector de porcentaje lingüístico se calcula para cada  $\Sigma CP$  empleando los totales:

$Total_{\Sigma CP_{Actitud}^{Humano}} (507.69)$   $Total_{\Sigma CP_{Actitud}^{Agente}} (143.61)$ , respectivamente:

- $\Sigma CP_{Actitud}^{Human} = \{(wise, 0.240), (brave, 0.569), (cau-$

$tious, 0.172), (passive, 0.017)\}$

- $\Sigma CP_{Actitud}^{Bot} = \{(wise, 0.122), (brave, 0.709), (cautious, 0.097), (passive, 0.075)\}$

Ahora, la similitud  $S_{REF}(\Sigma CP_{Actitud}^{Human}, \Sigma CP_{Actitud}^{Bot})$  se calcula con:  $REF(0.240, 0.122) = 1 - |0.240 - 0.122| = 0.882$ ,  $REF(0.569, 0.172) = 1 - |0.569 - 0.172| = 0.882$ ,  $REF(0.172, 0.097) = 1 - |0.172 - 0.097| = 0.925$  y  $REF(0.017, 0.075) = 1 - |0.017 - 0.075| = 0.942$  Por tanto,  $S_{REF}(\Sigma CP_{Actitud}^{Human}, \Sigma CP_{Actitud}^{Bot}) = \frac{3.402}{4} = 0.838$ . El resto de similitudes se calcula de forma similar. La puntuación final, junto al perfil de comportamiento obtenido para el jugador humano y el agente, proporciona al alumno una referencia sobre la calidad de los algoritmos implementados para los agentes actuando en el videojuego.

#### IV. Hacia una herramienta de apoyo a la docencia y el aprendizaje de algoritmos

Para llevar a cabo las ideas planteadas y definidas en las secciones anteriores se optó por el desarrollo una plataforma web que permite a cada estudiante obtener un informe de evaluación de forma automática que le proporcionará retroalimentación de forma inmediata sobre la calidad de implementación de sus agentes. La herramienta permite realizar una comparación entre el comportamiento de un jugador humano y los agentes desarrollados en los proyectos. De esta forma el alumno obtiene una nota de referencia de credibilidad de los mismos.

Esto puede verse como un test de turing permitiéndole testear a partir de las trazas de ejecución <sup>1</sup> que genera su proyecto un informe sobre el perfil de comportamiento de sus agentes inteligentes. A la herramienta se accede a través de la siguiente URL:

<http://www.youractionsdefineyou.com/assess>

La ventana principal muestra dos opciones: log in y register. El registro de un usuario consiste en introducir el correo electrónico, nombre de usuario, RUT (el equivalente al DNI español) y una clave. Para confirmar que el registro en la aplicación se ha realizado correctamente se enviará un correo electrónico al usuario. Una vez realizado el registro, el usuario puede ingresar introduciendo su usuario y clave. Una vez dentro de la aplicación, el informe de perfil de comportamiento se puede obtener seleccionando y cargando un archivo de traza de ejecución, cuando este archivo se carga el informe se obtiene automáticamente.

#### V. Agradecimientos

Al proyecto interno de la Universidad del Bío-Bío 170915

<sup>1</sup>[http://youractionsdefineyou.com/assess/web/examples\\_traces](http://youractionsdefineyou.com/assess/web/examples_traces)

## HUMAN BEHAVIOR PROFILE

The human player showed several brave attitudes. Definitely, many situations were safe. The human player proved to be capable of performing several good movements. The human player displayed an expert skill level several times. The human player proved to be skillful several times. During the most of the execution, the measured use of resources demonstrates an operation that is many times very efficient.

Grade: 7



## BOT BEHAVIOR PROFILE

During the most of the game, the bot showed many brave attitudes. Definitely, many situations were dangerous. The bot proved to be capable of performing several kamikaze movements. The bot displayed an beginner skill level several times. With great certainty, the bot proved to be improvable many times. During the most of the execution, the measured use of resources demonstrates an operation that is many times efficient.

Grade: 5.15



Fig. 2. Similitud entre los informes de comportamiento generados para el jugador humano y los agentes

2/R. Al grupo de investigación SOMOS (Software-MOdeling-Science) con referencia GI170315/EF

## VI. Conclusiones y trabajo futuro

En este trabajo se ha tratado el tema de la evaluación de los sistemas de Inteligencia Artificial (fuerte y débil) en el ámbito de los videojuegos. Se ha planteado la idea de evaluar la “inteligencia humana” de los agentes artificiales y se ha presentado un método para medir la “credibilidad” de los mismos analizando su comportamiento y comparándolo con el de los jugadores humanos. El método permite obtener de forma automática un informe sobre el comportamiento del jugador humano que puede compararse con la del agente. Para ello, se ha definido una medida de similitud entre las percepciones computacionales resumen encargadas de capturar y sintetizar los eventos ocurridos durante las partidas.

Esta es una primera aproximación hacia un marco más amplio y aún queda mucho trabajo por hacer. Nos gustaría incorporar en un futuro más detalles que enriquezcan la evaluación de los proyectos. Permitir que el sistema pueda entregar recomendaciones más ricas y detalladas sobre los fallos cometidos por los alumnos durante el diseño e implementación de los algoritmos de Inteligencia Artificial.

## References

- [1] Bustice, H., Barrenechea, E., Pagola, M. Restricted Equivalence Functions. *Fuzzy Sets and Systems* 157, pp. 2333-2346 (2006).
- [2] García-Honrado, I., Fortuny, J. M., Ferrer, M., Morera, L. (2016). Análisis del aprovechamiento de oportunidades de aprendizaje generadas en la discusión en gran grupo de un problema de transformaciones geométricas. *Investigación en Educación Matemática XX*, 253-264.
- [3] Gkatzia, D., Hastie, H., Janarthnam, S., & Lemon, O. Generating student feedback from time-series data using Reinforcement Learning. In *Proceedings of the 14th European Workshop on Natural Language Generation* (pp. 115-124).
- [4] Hernández-Orallo, J. (2017). Evaluation in artificial intelligence: from task-oriented to ability-oriented measurement. *Artificial Intelligence Review*, 48(3), 397-447.
- [5] Hingston, P. (2009). A turing test for computer game bots. *IEEE Transactions on Computational Intelligence and AI in Games*, 1(3), 169-186.
- [6] Livingstone, D. (2006). Turing's test and believable AI in games. *Computers in Entertainment (CIE)*, 4(1), 6.
- [7] López de Mantaras Badia, R., Mesenguer González, P. (2017) ¿Qué sabemos de? *Inteligencia Artificial Editorial: CSIC y Catarata*
- [8] Phedes 2017 Phedes Lab: Linguistic Description of Complex Phenomena. <http://phedes.com/>
- [9] Ramos-Soto, A., Vazquez-Barreiros, B., Bugarín, A., Gewerc, A., & Barro, S. Evaluation of a Data To Text System for Verbalizing a Learning Analytics Dashboard. *International Journal of Intelligent Systems*, 32(2), 177-193.
- [10] Rubio-Manzano, C., & Trivino, G. Improving player experience in Computer Games by using players' behavior analysis and linguistic descriptions. *International Journal of Human-Computer Studies*, 95, 27-38.
- [11] Rubio-Manzano, C. Similarity measure between linguistic terms by using restricted equivalence functions and its application to expert systems 9th European Symposium on Computational Intelligence and Mathematics. *Faro (Portugal)*, October 4th-7th, 2017.
- [12] Sánchez-Torrubia, M. G., Torres-Blanc, C., & Trivino, G. (2012). An approach to automatic learning assessment based on the computational theory of perceptions. *Expert Systems with Applications*, 39(15), 12177-12191.
- [13] Soni, P. & Hingston, P. (2008, June). Bots trained to play like a human are more fun. In *Neural Networks, 2008. IJCNN 2008.(IEEE World Congress on Computational Intelligence)*. IEEE International Joint Conference on (pp. 363-369). IEEE.
- [14] Trivino, G & Sugeno, M. Towards linguistic descriptions of phenomena. *International Journal of Approximate Reasoning*, 54(1), 22-34.



# Statistical Language Modelling for Automatic Story Generation

Marta Vicente, Cristina Barros and Elena Lloret

University of Alicante

{mvicente,cbarros,elloret}@dlsi.ua.es

**Abstract**—This abstract summarises the research work published in the *Journal of Intelligent & Fuzzy Systems*, vol. 34 (5), 2018. In this publication, we proposed and analysed an end-to-end Natural Language Generation approach to automatically create fiction stories using statistical language models, both in the macroplanning and surface realisation stages. The results obtained from the evaluation conducted showed that the combination of the aforementioned stages in an end-to-end approach was appropriate and had positive effects in the resulting generated text. Specifically, the use of language models allows the generation task to be more flexible, as far as the adaptation of the approach to different languages, domains and textual genres is concerned.

## I. INTRODUCTION

The generation of stories is a difficult task in which complex cognitive processes are involved. The process of creating a story requires both knowledge of the world and ability to perform tasks such as planning events or resolving situations [8]. Natural Language Generation (NLG), as a subarea of Natural Language Processing, can provide, in turn, useful mechanisms to create a story automatically. In order to generate a text, the responsibilities of NLG include, to determine “*what to say*” and “*how to say it*”. This dual purpose can be addressed as a pipeline of two stages: macroplanning and surface realisation. Macroplanning is in charge of determining the structure of the text to be produced, as well as deciding the content it will have. Surface realisation is focused on taking that content as input, and transforming it into human language, using the appropriate vocabulary, syntactic structures, etc.

In this research work, we studied the problem of whether a story could be automatically generated from scratch without having any clue about the characters, topics, or facts to describe, just having some previous information from other existing stories that could serve as an inspiration source.

To achieve this, a statistical perspective was adopted. Specifically, macroplanning was addressed using Positional Language Models (PLM) while, in the surface realisation stage, Factored Language Models (FLM) were employed. As output, the approach produced a set of sentences in the form of a story, inspired by the structure and linguistic elements of an existing one, but with a different realisation (different events, actions and vocabulary).

The preliminary results showed that statistical language models can definitely contribute to the development of more adaptive and flexible story generation systems, thus providing

mechanisms that can be extended to other kind of domains, languages and textual genres.

## II. BACKGROUND

Recent work in narrative and storytelling has been focused on regenerating stories from graphs of intentions [4] or approaching the task working with discourse and story planning simultaneously to differentiate levels of narrative [9]. Regarding the statistical models used in this research, on the one hand, PLMs have been successfully employed in some language-related areas such as summarisation [2] or information retrieval [5]. However, they have not been directly implemented within the generation framework. Also, in recent years, FLM have been employed for NLG, such in BAGEL [6] or in [7]. The main novelty of our approach is that human intervention in the NLG process is not necessary at any stage, so we avoid the hand-coding of the story constraints, and we increase the automation of the generation process.

## III. END-TO-END STORY GENERATION APPROACH

The NLG approach consists of a macroplanning and a surface realisation stage that are sequentially executed.

### A. Macroplanning.

In the NLG process, macroplanning is responsible for both selecting the content and providing the structure that articulates the output.

Different from the common bag-of-words perspective, PLMs are able to take into account the positions of words together with the number of their occurrences. On this basis, for each position  $i$  of a text, we computed a model  $P(w | i)$  by which every word  $w$  of the vocabulary gets a value for that location  $i$  conditioned by the distance to other appearances of that word within the text.

Using this model, we could obtain the distribution of the elements along the text, considering those with higher values the most relevant ones. We translated this information into a document plan.

### B. Surface realisation.

From the document plan provided by the macroplanning stage, the realisation of the final output was performed relying on FLMs. For this type of models, a word  $w$  is seen as a collection of  $K$  parallel factors, they can be any linguistic feature related to the word, from whose combination a statistical model is built.

We used over-generation and ranking, where a set of candidate sentences is generated and ranked according to the probabilities given by the model. We took into account a simple grammar and prioritised the information specified in the document plan to select the words belonging to each candidate.

#### IV. EXPERIMENTAL SCENARIO

Some experiments were conducted to analyse the performance of the approach. Each stage was empirically adjusted to achieve an optimal configuration and afterwards, a subset of the corpora was used to produce the document plans. The surface realisation module generated from them the final stories. In this research work, from each document plan only one story was generated.

Regarding the macroplanning, some decisions were made about the vocabulary and the design of the document plan itself. The vocabulary was formed by synsets in order to incorporate grammatical and semantic features to the process and, to conform the document plan, we produced one line per each sentence of the source text, containing synsets of verbs, nouns, adjectives and adverbs.

Once the document plans were created, the surface realisation was in charge of generating the final stories following the guidelines the plans had established while being also consistent with the grammar.

We worked with a collection of English children stories, including the Lobo and Matos corpus [3] and automatically gathered stories<sup>1</sup> from *Bedtime stories* and *Hans Christian Andersen: Fairy Tales and Stories*.

#### V. EVALUATION, RESULTS AND DISCUSSION

In order to evaluate how the document plan impacted in the generated text as well as the quality of the generated fiction story, we performed two tests.

On the one hand, we evaluated how the synsets and their distribution in the document plan were reflected in the resulting stories. To estimate the influence of the document plan in the generation of the new tales, we analysed the relation between both documents, measuring how the elements were shared.

On the other hand, a user evaluation was performed to analyse the general problems and errors of the approach. We used a point score scale, and three users manually read and analysed a set of stories in order to assess the system performance and provide feedback based on the detection of problems. They shed light on the limitations of our approach.

At a word level, the users highlighted the appropriate variety and richness of the vocabulary. Even though, for some examples they remarked that it would be adequate to use more synonyms, in order to prevent finding consecutive sentences repeating exactly the same terms.

At a sentence level, the evaluation revealed that, independently of the relation with their neighbours, sentences, in general, would become more meaningful once inflected. To

understand why some excerpts present an oddly shape, we should attend to the grammar beneath, on the one side, and to the semantic aspect, on the other.

Thirdly, at the level of discourse, adapted to our defined framework, the users were able to identify themes and guiding threads. They also noted the presence of characters as being involved in possible actions. They stated that the repetition of elements was essential to detect those underlying features. This reinforces our initial consideration regarding the relevance of a proper distribution of the elements through the text. Along with these comments, the users indicated that in some of the examples the absence of enough information impeded the assumption of any of those elements (themes, characters), but mostly this difficulty was related to the semantics of the generated tales.

#### VI. CONCLUSION

This paper proposed and evaluated a novel end-to-end NLG approach for generating fiction stories that integrates the macroplanning and the surface realisation stages within a statistical framework.

Evaluation showed that all the sentences generated by the approach contained elements from the document plan, 81% of the sentences having at least one of the highest rated elements. Furthermore, as there were not only one type of element within the document plan, on average, 83% of the content of each generated tale came from the document plan. Concerning the results of the user evaluation, we received positive feedback from 47% of the generated stories. We consider these results to be an indicator of the positive effects of combining the two stages (i.e. macroplanning and surface realisation).

Although the results are still preliminary, there are some issues which need to be improved and some interesting research lines opening new directions for future work.

#### ACKNOWLEDGMENT

Funded by the Generalitat Valenciana (ACIF/2016/501) and Spanish Government (TIN2015-65100-R, TIN2015-65136-C2-2-R).

#### REFERENCES

- [1] C. Baker, C.J. Fillmore, and J.B. Lowe, *The Berkeley FrameNet Project*, in: Procs. of the 36th Meeting of the ACL – Volume 1, 1998, 86–90.
- [2] S. Liu et al, *Positional Language Modelling for Extractive Broadcast News Speech Summarization*, in: INTERSPEECH, 2015, 2729–33.
- [3] P.V. Lobo, and D.M. De Matos, *Fairy Tale Corpus Organization Using Latent Semantic Mapping and an Item-to-Item Top-N Recommendation Algorithm*, in: LREC, 2010.
- [4] S.M. Lukin, L.I. Reed and M.A. Walker, *Generating Sentence Planning Variations for Story Telling*, in: 16th SIGdial, 2015, 188.
- [5] Y. Lv, Yuanhua, and C. Zhai, *Positional Language Models for Information Retrieval*, in: Procs. of the 32nd ACM SIGIR, New York, 2009, 299–306.
- [6] F. Mairesse and S. Young, *Stochastic Language Generation in Dialogue Using Factored Language Models*, Computational Linguistics, 40(4), 2014, 763–99.
- [7] E.M. Novais, and I. Paraboni, *Portuguese Text Generation Using Factored Language Models*, Journal of the Brazilian Computer Society 19(2), 2012, 135–46.
- [8] S.R. Turner, *Minstrel: A Computer Model of Creativity and Storytelling*, Ph.D. Dissertation. University of California at Los Angeles, 1993.
- [9] D.R. Winer and R.M. Young, *Discourse-Driven Narrative Generation with Bipartite Planning*, in: The 9th INLG, 2016, 11–20.

<sup>1</sup><https://freestoriesforkids.com/>, <http://hca.gilead.org.il/>

**XIX Congreso Español  
sobre Tecnologías  
y Lógica Fuzzy  
(XIX ESTYLF)**

ESTYLF 12: SESIÓN ESPECIAL  
SOFT COMPUTING Y  
GENERACIÓN DEL  
LENGUAJE NATURAL II

**Organizadores:**

ALBERTO BUGARÍN, NICOLÁS MARÍN,  
ALEJANDRO RAMOS, DANIEL SÁNCHEZ







# Descripciones lingüísticas de datos de observación meteorológica usando temple simulado

Andrea Cascallar Fuentes, Alejandro Ramos Soto, Alberto J. Bugarín Diz

{andrea.cascallar.fuentes, alejandro.ramos, alberto.bugarin.diz}@usc.es

Centro Singular de Investigación en Tecnoloxías da Información (CiTIUS), Universidade de Santiago de Compostela

**Resumen**—En este trabajo presentamos una aproximación para la generación de descripciones lingüísticas en tiempo real sobre datos de observación meteorológica proporcionados por la Agencia Meteorológica gallega (MeteoGalicia). Las descripciones son sentencias cuantificadas borrosas, que incluyen referencias geográficas imprecisas, y resultan válidas para la etapa de determinación de contenidos de un sistema de Generación de Lenguaje Natural. La generación de las descripciones va guiada por la metaheurística Temple Simulado, que permite seleccionar las descripciones lingüísticas más adecuadas, de acuerdo con un conjunto de criterios objetivos.

**Index Terms**—Descripciones lingüísticas de datos, Generación de lenguaje natural, Computación con palabras.

## I. INTRODUCCIÓN

Ante la ingente cantidad de datos presente actualmente en todas las facetas de la vida, la Inteligencia Artificial provee herramientas que permiten analizar conjuntos de datos con la finalidad de extraer información útil y comprensible para usuarios y expertos, basada en el potencial del lenguaje humano. Por ejemplo, la generación de lenguaje natural (NLG, en inglés) se ocupa de la generación de texto a partir de diversas fuentes de datos [1]. Dentro de este campo son de interés los sistemas *data-to-text* (D2T) [2], que generan textos a partir de conjuntos o series de datos numéricos o simbólicos.

De forma complementaria a los sistemas D2T, las descripciones lingüísticas de datos (LDD, en inglés) proporcionan mecanismos para obtener resúmenes sintéticos de conjuntos de datos numéricos, generalmente basados en el uso de sentencias cuantificadas borrosas [3]. Este tipo de aproximaciones, surgidas a partir del concepto de protoforma definido por Zadeh [4], permiten modelar la imprecisión de los términos lingüísticos inherente al lenguaje humano, aunque su uso en sistemas reales es muy limitada por el momento [5]. Según sus componentes, existen dos tipos de protoformas: tipo I (“ $Q Y$  son  $S$ ”) donde  $Q$  es un cuantificador,  $Y$  es un conjunto de elementos y  $S$  es un resumen; y tipo II (“ $Q KY$  son  $S$ ”) donde además de los componentes presentes en las de tipo I se añade un calificador  $K$ .

Es precisamente en la faceta aplicada de LDD donde se centra el objetivo de este trabajo: la generación de descripciones lingüísticas mediante temple simulado [6] sobre datos meteorológicos en tiempo real proporcionados por MeteoGalicia [7] para el conjunto de los 314 municipios de Galicia, introduciendo además el uso de referencias geográficas.

## II. TRABAJOS RELACIONADOS

Actualmente, existen numerosos sistemas NLG, de los cuales una gran mayoría lo componen sistemas D2T [1], [8], [9]. Por ejemplo, uno de los sistemas de mayor impacto en el ámbito de la salud es el sistema BT45, dentro del proyecto BabyTalk [10], que genera informes a partir de datos recogidos durante 45 minutos sobre bebés que se encuentran en la UCI.

En el campo de LDD, la mayor parte de aproximaciones propuestas generan sentencias cuantificadas como “La mayoría de las personas son altas” (tipo I) o “La mayoría de las personas altas son rubias” (tipo II) [3], [9], [11]. Este tipo de propuestas se han aplicado a una gran variedad de casos de uso, principalmente sobre series de datos temporales, como datos de consumo energético [12], fondos de inversión [13], actividad física [14], [15] o el flujo de pacientes en hospitales [16], entre otros. En ámbitos de aplicación real, GALiWeather [5] es un sistema D2T meteorológico que emplea LDD para ciertas tareas de extracción de información, lo que ejemplifica la complementariedad que existe entre ambas disciplinas.

Otro aspecto importante en este campo es la utilización de estrategias de búsqueda, tanto heurísticas [5], [16] como basadas en algoritmos genéticos [17]–[19], para la obtención de sentencias cuantificadas con un nivel de calidad descriptiva suficiente, en problemas donde su número es demasiado grande como para obtenerlas exhaustivamente en su totalidad.

## III. MOTIVACIÓN

Nuestro caso de uso consiste en datos de observación meteorológica proporcionados en tiempo cuasi real por MeteoGalicia [7] para las variables estado del cielo, viento y temperatura. Dada la alta frecuencia de actualización de dichos datos, aproximadamente a cada hora, se justifica la necesidad de generar descripciones en el menor tiempo posible. Además, dado que dichos datos se encuentran caracterizados geográficamente, las descripciones en nuestra propuesta contemplan también la inclusión de referencias geográficas vagas como “norte” o “este”.

Concretamente, nuestra solución genera descripciones lingüísticas basadas en proposiciones cuantificadas de tipo I, donde  $Q$  es un cuantificador,  $X$  es una variable lingüística definida a partir de las variables meteorológicas y  $A$  es uno de sus valores (“En algunos ayuntamientos el cielo está despejado”); y II donde se añade un descriptor geográfico (“En algunos ayuntamientos en el Norte el cielo está despejado”), que pueden incluir una o más variables meteorológicas.

En nuestro caso, la cantidad de datos disponibles y la necesidad de disponer de una solución computacionalmente poco costosa para la obtención de las descripciones, debido a las restricciones temporales que se deben cumplir, aconsejan la utilización de una estrategia de búsqueda más simple que las de tipo evolutivo comentadas anteriormente. Por ello, proponemos utilizar la metaheurística temple simulado, de muy reducido coste computacional y que ha sido utilizada para abordar diversos problemas [20] [21], obteniendo buenas soluciones en comparación con otras metaheurísticas.

#### IV. GENERACIÓN DE DESCRIPCIONES METEOROLÓGICAS

La solución propuesta utiliza datos numéricos para generar descripciones de observación meteorológica en tiempo real de la comunidad autónoma de Galicia.

MeteoGalicia ofrece un servicio web que muestra datos de observación sobre el estado meteorológico actual de los ayuntamientos gallegos [7], actualizados aproximadamente cada hora.

##### IV-A. Conocimiento del dominio

En base a las variables meteorológicas, se definen las siguientes variables lingüísticas:

- Estado del cielo: sus valores son códigos numéricos que categorizan el la cobertura nubosa y el nivel de precipitación. A partir de esta variable se crea una variable lingüística con el mismo nombre definida del mismo modo.
- Viento: los posibles valores son códigos numéricos que codifican intensidad y dirección del viento. A partir de esta variable se crea una variable lingüística con el mismo nombre que respeta la definición original.
- Temperatura: se crean dos variables lingüísticas, una para las temperaturas máximas y otra para las mínimas. La temperatura actual de un ayuntamiento se compara con las máximas y las mínimas del mes actual del registro de datos históricos. Para la temperatura actual de cada ayuntamiento  $t_i$ , las etiquetas que toman las variables lingüísticas se calculan utilizando la media  $\bar{x}$  y la desviación típica  $\sigma$  del mes actual de los datos históricos.

Las protoformas tipo I, siguen la plantilla “En Q ayuntamientos A”, donde Q es un cuantificador y A puede ser una o varias de las estructuras definidas en la Tabla I (“En pocos ayuntamientos el estado del cielo es soleado y la temperatura es baja con respecto a las máximas y normal con respecto a las mínimas”). Se han definido siete cuantificadores borrosos (“ninguno”, “pocos”, “algunos”, “aproximadamente la mitad”, “bastantes”, “casi todos”, “todos”), sobre el porcentaje de ayuntamientos (PA) que verifican la sentencia.

Las protoformas tipo II siguen la plantilla “En Q ayuntamientos en G A”, donde Q y A son como en el caso anterior y G es un descriptor geográfico (“En algunos ayuntamientos del Sur el estado del cielo es soleado”).

Los descriptores geográficos, definidos de forma borrosa, son {Norte, Sur, Este, Oeste, Centro} definidos de la siguiente forma:

- Sur: definido mediante el conjunto borroso trapezoidal de soporte [41.75, 42.57] y núcleo [41.75, 42.16]
- CentroLatitud: definido mediante el conjunto borroso trapezoidal de soporte [42.16, 43.39] y núcleo [42.57, 42.98]
- Norte: definido mediante el conjunto borroso trapezoidal de soporte [42.98, 43.8] y núcleo [43.39, 43.8]
- Oeste: definido mediante el conjunto borroso trapezoidal de soporte [-9.31, -8.266] y núcleo [-9.31, -8.788]
- CentroLongitud: definido mediante el conjunto borroso trapezoidal de soporte [-8.788, -7.222] y núcleo [-8.266, -7.744]
- Este: definido mediante el conjunto borroso trapezoidal de soporte [-7.744, -6.7] y núcleo [-7.222, -6.7]

Para considerar la parte geográfica de la descripción tenemos datos meteorológicos geolocalizados, es decir, se dispone de la localización de cada ayuntamiento. Para cada localización se toma la etiqueta que mejor la representa calculando el grado de cumplimiento aplicando el modelo de cuantificación de Zadeh.

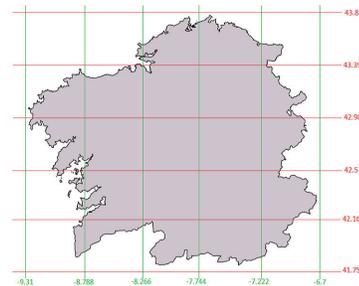


Figura 1: Coordenadas de referencia para la definición de los descriptores geográficos.

Tabla I: Plantillas de texto

Variable lingüística	Plantilla
Estado del cielo	el estado del cielo es <valor>
Viento	el viento tiene dirección <valor_dirección> e intensidad <valor_intensidad>
Temperatura	la temperatura es <valor_máx> con respecto a las máximas y <valor_min> con respecto a las mínimas

##### IV-B. Generación de descripciones lingüísticas

Debido a que el objetivo de nuestra solución es generar sentencias que describan la situación meteorológica en tiempo real, y que la gran mayoría de estaciones meteorológicas sirven datos diezminutales, hemos fijado como restricción que el tiempo de ejecución para la obtención de las descripciones no supere los 5 minutos<sup>1</sup>. Esto se debe a que nuestra solución

<sup>1</sup>Pruebas ejecutadas en un Intel Core i7-6700HQ @2.60GHz 2.59GHz con 16 GB de RAM



se centra en la fase de determinación de contenido de un sistema NLG, por lo tanto, a la hora de abordar las demás fases para desarrollar un sistema completo, el tiempo de ejecución necesario será mayor. Por esta razón y teniendo en cuenta que se busca describir el estado actual en tiempo real, a partir de la versión base hemos introducido una serie de optimizaciones.

En primer lugar, para cada ayuntamiento se calcula el grado de cumplimiento de su temperatura actual con respecto a las etiquetas que pueden tomar las dos variables lingüísticas. Para realizar este cálculo, utilizando el valor de la media y la desviación típica, para cada ayuntamiento se guarda el grado de cumplimiento para cada una de las etiquetas definidas en la Sección III. Además, para cada posible valor de la variable “temperatura”  $L$ , se calcula el grado de pertenencia del conjunto de ayuntamientos como se muestra en la expresión 1 siendo  $n$  el número de ayuntamientos,  $\mu_L$  la función que evalúa el grado de cumplimiento y  $t_i$  la temperatura actual de cada ayuntamiento.

$$\mu(L) = \frac{\sum_{i=1}^{|n|} \mu_L(t_i)}{n} \quad (1)$$

**IV-B1. Generación de sentencias tipo I:** Esta parte del sistema se centra en generar las sentencias de tipo I a partir de los datos obtenidos.

**Versión inicial.** Genera todas las sentencias posibles y, para cada una de ellas, se calcula su grado de cumplimiento. Este cálculo se realiza de forma diferente si la sentencia contiene una única variable lingüística o si está compuesta por más de una.

Para las descripciones  $D$  donde solo se describe una variable se aplica el modelo de cuantificación de Zadeh. En el caso de las variables “crisp” el grado de cumplimiento es 1 si el valor actual  $v_i$  coincide con la etiqueta  $S$  y 0 en caso contrario.

$$\mu(Q \text{ X son } A) = Q\left(\frac{\sum_{i=1}^{|n|} \mu_S(v_i)}{n}\right) \quad (2)$$

Para las descripciones  $D$  donde se describe más de una variable, debemos aplicar, siguiendo nuevamente el modelo de cuantificación de Zadeh, la conjunción de todas las variables, utilizando la t-norma mínimo:

$$\mu(Q \text{ X son } A) = Q\left(\frac{\sum_{i=1}^{|n|} \mu_{S1}(v_{S1i}) \cap \dots \cap \mu_{Sm}(v_{Smi})}{n}\right) \quad (3)$$

Al ejecutar esta versión se obtiene un total de 63.875 descripciones y la ejecución tarda en completarse aproximadamente 35 minutos.

**Optimización 1.** La versión anterior no cumple la restricción, por lo tanto es necesario optimizarla.

Por muy diversas que sean las condiciones meteorológicas, no se van a dar todos los posibles valores para las variables contempladas. Esto es debido, en parte, al tamaño reducido de esta región.

Para reducir el coste temporal que supone generar todas las posibles combinaciones, se propone implementar una

optimización que descarte los valores no presentes en el panorama actual. De este modo se reduce notoriamente el tiempo necesario para completar una ejecución. El tiempo necesario para obtener las descripciones varía entre 50 y 60 segundos y se obtienen alrededor de 2000. Además, eliminando situaciones meteorológicas que no están presentes se obtienen descripciones más representativas del mapa.

**Mejores soluciones.** Aplicando esta optimización se consigue una mejora notoria, sin embargo, los resultados obtenidos no son suficientemente representativos. Para solucionar este problema se proponen las siguientes mejoras:

- Eliminar descripciones “Ninguno”: este cuantificador es útil en cuanto que aísla las descripciones que no se cumplen, sin embargo, éstas no son, en general, útiles para el usuario, por lo tanto, se descartan.
- Umbral en el grado de cumplimiento: algunas sentencias describen casos poco relevantes, esto es, tienen un grado de cumplimiento muy bajo. Para evitar esta situación se define un umbral  $u = 0,5$  eliminando aquellas sentencias que tengan un grado de cumplimiento inferior.
- Ordenación: para evaluar las descripciones se propone utilizar dos criterios además del grado de cumplimiento: cobertura del cuantificador, prefiriendo sentencias que abarquen mayor extensión y así evitar describir una misma situación mediante varias sentencias referidas a extensiones más reducidas; y tamaño de la sentencia, prefiriendo sentencias que comprendan un número mayor de variables, ya que de esta forma se reduce el número de sentencias y estas son más específicas. Las sentencias se ordenan según los criterios descritos anteriormente, priorizados por el siguiente orden: grado de cumplimiento, cobertura del cuantificador y longitud de la sentencia. Una excepción en dicho orden son las descripciones del cuantificador “Pocos”, que se sitúan después de las de cuantificadores con mayor cobertura de modo que, aunque según la ordenación indicada podrían ser seleccionadas en detrimento de algunas sentencias con mayor cobertura, se colocan después de modo que el usuario obtenga información más general y pueda acceder a éstas si necesita más grado de detalle.

Una vez que se han aplicado estas mejoras, se define un número máximo de descripciones que se van a mostrar ya que un número elevado de descripciones puede provocar que el texto generado no sea útil para el usuario.

En la Tabla II se muestra una comparativa entre las diferentes versiones.

Tabla II: Resumen versiones tipo I

Versión	Tamaño solución	Tiempo de ejecución
Inicial	63875	~35 minutos
Optimización 1	~2000	50-60 segundos
Mejores soluciones	un máximo de 100	50-60 segundos

**IV-B2. Generación de sentencias tipo II:** Se parte de una versión inicial, donde se generan todas las combinaciones posibles, y a partir de ahí se proponen optimizaciones.

Para estas descripciones hay que calcular, para cada ayuntamiento, los grados de pertenencia con respecto a los descriptores geográficos. Este cálculo se realiza utilizando la coordenada correspondiente y calculado su grado de cumplimiento. Los cálculos para “Centro” difieren del resto ya que está formado por dos componentes. El proceso es el siguiente: para cada ayuntamiento se calcula el grado de cumplimiento para cada coordenada, se aplica la t-norma mínimo entre estos dos valores y al valor resultante se le aplica el descriptor geográfico, calculando el grado de cumplimiento.

$$\mu_{Centro}(longitud_i, latitud_i) = \mu_{CentroLongitud}(longitud_i) \cap \mu_{CentroLatitud}(latitud_i) \quad (4)$$

**Versión inicial.** Genera todas las sentencias posibles y, para cada una de ellas, se calcula su grado de cumplimiento con la finalidad de saber cuáles son las descripciones más representativas.

$$\mu(Q \text{ X son A en } G) = Q \left( \frac{\sum_{i=1}^{|n|} \mu_G(x_i) \cap \mu_{S1}(x_i) \cap \dots \cap \mu_{Sm}(x_i)}{\sum_{i=1}^{|n|} (\mu_G(x_i))} \right) \quad (5)$$

Para obtener todas las descripciones, el sistema necesita aproximadamente 3 días y se generan 1094170 descripciones, incumpliendo la restricción temporal.

**Optimización 1.** La primera optimización es eliminar los valores no presentes, como en las de tipo I, reduciendo el coste temporal a aproximadamente 8 horas y obteniendo alrededor de 13000 descripciones.

## V. ALGORITMO DE BÚSQUEDA META-HEURÍSTICO

Debido a la elevada cantidad de descripciones que se generan de tipo II y al coste temporal que esto supone, se propone el uso de un algoritmo de búsqueda metaheurística para la extracción de información relevante consumiendo menos recursos.

En general, los algoritmos basados en poblaciones no parecen la mejor opción para este caso. Los algoritmos metaheurísticos basados en métodos constructivos tampoco son una buena opción ya que, en este caso, la solución inicial debe tener un mínimo de componentes. Las soluciones basadas en trayectorias pueden aplicarse en este caso, ya que utilizan una heurística de búsqueda local que explora posibles soluciones siguiendo una trayectoria en el espacio de búsqueda. Realizando un análisis de los algoritmos más utilizados se concluye que el Temple Simulado [6] es una buena alternativa. Es un algoritmo de búsqueda por entornos con un criterio probabilístico de aceptación de soluciones inspirado en la Termodinámica. En cada iteración se genera un determinado número de vecinos, con cierta probabilidad de aceptar soluciones peores para evitar que el algoritmo no se estanque en un óptimo local.

Este algoritmo cuenta con una serie de parámetros configurables de modo que, realizando un estudio empírico, se puedan establecer valores que obtengan resultados de calidad.

A continuación se muestran los valores establecidos después de realizar el estudio.

- Valor inicial del parámetro de control  $T_0$ : esta variable se debe inicializar a un valor suficientemente alto ya que, si es muy bajo converge demasiado rápido y si es muy alto tarda en converger. Después de experimentar con diversos valores se inicializa con un valor proporcional al número máximo de descripciones posible, tomando como parámetros  $\mu = 0,01$  y  $\phi = 0,999$ .

$$T_0 = (\mu / -\ln(\phi)) / MAX\_SOLUCIONES \quad (6)$$

- Solución inicial  $S_0$ : después de probar diversas alternativas,  $S_0$  se inicializa con la mejor sentencia formada por una única variable lingüística obtenida aplicando los criterios de evaluación descritos anteriormente.
- Nueva solución: la forma de generar una nueva solución es modificar [1, 4] componentes aleatoriamente. Con este método en ocasiones el algoritmo se queda estancado, para solucionar esto, se define un parámetro *maxRepeated*, que define el número máximo de soluciones repetidas en una iteración. Si se alcanza este valor, se genera una nueva solución completamente aleatoria, evitando el estancamiento.
- Velocidad y mecanismo de enfriamiento:  $MAX\_CANDIDATAS = 300$  y  $MAX\_ACEPTADAS = 30$  se consigue un buen balance en cuanto a soluciones peores aceptadas y la velocidad de enfriamiento. En cuanto al mecanismo de enfriamiento, se utiliza el Esquema de Cauchy.
- Condición de parada: después de experimentar con otras alternativas que no se adecúan a este problema, se experimenta con una condición de parada que está formada por dos condiciones: número máximo de iteraciones y máximo de intentos fallidos de generar nuevas soluciones para cada iteración. Para esto se definen dos parámetros:  $MAX\_ITER = 2300$ , que establece el número máximo de iteraciones que el algoritmo puede hacer y  $MAX\_NEIGHBOUR\_ATTEMPTS = 2000$ , que define el número máximo de intentos de generar una nueva solución candidata en una iteración.
- Condición de aceptación: realizamos una experimentación con diferentes opciones concluyendo que la que mejor resultados ofrece es la expresión 7, donde se da preferencia al grado de cumplimiento, aceptando las nuevas soluciones que mejoren el de la actual, y a la cobertura, aceptando soluciones con mayor cobertura aunque el grado de cumplimiento sea inferior.

$$\begin{aligned} & (cobertura(S_{cand}) \leq cobertura(S_{act}) \ \&\& \\ & \mu(S_{cand}) \geq \mu(S_{act}) \ \&\& \mu(S_{cand} > 0)) \ || \\ & (cobertura(S_{cand}) > cobertura(S_{act}) \ \&\& \\ & \mu(S_{cand} > 0)) \ || (\mu(S_{cand} > 0)) \ \&\& \\ & \text{aleatorio} < e^{-\delta/T_k} \end{aligned} \quad (7)$$



A esta configuración se le aplican las mismas optimizaciones que en las descripciones de tipo I descritas en la Sección IV-B1:

Aplicando este algoritmo, el tiempo de ejecución es de aproximadamente 2 minutos y el conjunto de descripciones que se muestra tiene un tamaño de aproximadamente 400 sentencias ofreciendo una descripción representativa del estado meteorológico.

Tabla III: Resumen versiones tipo II

Versión	Tamaño solución	Tiempo de ejecución
Inicial	1094170	3 días
Optimización I	~13000	~8 horas
SA	~400	~2 minutos

## VI. EVALUACIÓN

Para evaluar el grado de adecuación de las descripciones a diferentes casos hemos generado cuatro mapas, en cada uno de los cuales se representa el estado de una de las variables (estado del cielo, viento, temperatura máxima y temperatura mínima). Se representa un meteoro por cada uno de los 314 ayuntamientos de Galicia.

Para las variables “estado del cielo” y “viento” los mapas se construyen utilizando los iconos que ofrece Meteogalicia. Para los componentes de la variable “temperatura” se utilizan los siguientes códigos que representan las posibles etiquetas de la variable lingüística “temperatura”: “MB” para “muy baja”, “B” para “baja”, “N” para “normal”, “A” para “alta” y “MA” para “muy alta”. Cada uno de estos códigos tiene un color desde azul oscuro para “MB” hasta rojo para “MA”. Debido al elevado número de iconos, interpretar correctamente la información visual es una tarea difícil.

En las tablas IV y V se muestran las mejores descripciones con respecto a los mapas que se muestran en la Figura 2. Estas descripciones son las 10 mejores obtenidas en cada caso después de ordenarlas siguiendo los tres criterios, descritos en IV-B1. Aunque las descripciones de tipo I proporcionan una idea general sobre el estado meteorológico, por sí solas no son suficientemente informativas. En este sentido, las descripciones de tipo II son de mayor utilidad ya que, al centrarse en regiones más pequeñas tienen en cuenta situaciones que las de tipo I no consideran precisamente por su carácter general.

Para comprobar la calidad de las descripciones se han realizado 20 ejecuciones en momentos del día diferentes durante dos semanas. Las descripciones de tipo I siempre obtuvieron buenos resultados en cuanto a que describen la situación meteorológica informando sobre los valores de las variables meteorológicas que más se repiten. Las descripciones de tipo II, en general también obtuvieron resultados representativos salvo en casos en los que un fenómeno ocurre en un área muy pequeña debido a la definición demasiado amplia del descriptor geográfico (por ejemplo cielos soleados en toda la región salvo en el extremo Norte de Galicia donde está “muy nublado”) de modo que no ocupa una posición relevante en el conjunto de soluciones resultante.

Tabla IV: Mejores 10 descripciones tipo I para 15 de septiembre a las 17:00 (Figura 2).

Descripción
En aproximadamente la mitad de ayuntamientos el estado del cielo es muy nublado
En aproximadamente la mitad de ayuntamientos el viento tiene dirección Norte e intensidad baja
En algunos ayuntamientos el cielo está muy nublado y la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En algunos ayuntamientos el viento tiene dirección Norte e intensidad baja y la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En algunos ayuntamientos la temperatura es baja con respecto a las máximas y muy alta con respecto a las mínimas
En bastantes ayuntamientos la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En algunos ayuntamientos el estado del cielo es nubes y claros
En algunos ayuntamientos el estado del cielo es muy nublado y el viento tiene dirección Norte e intensidad baja
En pocos ayuntamientos el estado del cielo es despejado y el viento tiene dirección Norte e intensidad baja

Tabla V: Mejores 10 descripciones tipo II para 15 de septiembre a las 17:00 (Figura 2).

Descripción
En aproximadamente la mitad de ayuntamientos del Este la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En algunos ayuntamientos del Oeste el viento tiene dirección Norte e intensidad baja
En algunos ayuntamientos del Oeste el estado del cielo es nubes y claros
En algunos ayuntamientos del Oeste el estado del cielo es muy nublado
En algunos ayuntamientos del Sur el viento tiene dirección Norte e intensidad baja
En algunos ayuntamientos del Sur la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En aproximadamente la mitad de ayuntamientos del Norte la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En algunos ayuntamientos del Este el viento tiene dirección Norte e intensidad baja
En algunos ayuntamientos del Este el estado del cielo es cubierto y la temperatura es baja con respecto a las máximas y alta con respecto a las mínimas
En algunos ayuntamientos del Sur el estado del cielo es muy nublado y la temperatura es baja con respecto a las máximas y muy alta con respecto a las mínimas

Hemos analizado cuantitativamente la calidad de las descripciones generadas con la metaheurística frente a la totalidad de descripciones posibles (en casos de uso donde esto último resultaba factible). Los resultados indican que la metaheurística genera: i) el 25 % de las descripciones de mayor calidad (utilizando como métrica de calidad la suma de las tres condiciones de evaluación normalizadas) si descartamos las que incluyen el cuantificador de menor cobertura espacial (el menos específico, “pocos ayuntamientos”), ii) el 40 % de las descripciones que incluyen los tres cuantificadores de mayor cobertura y iii) el 75 % de las descripciones que incluyen los dos cuantificadores de mayor cobertura (“casi todos” y “bastantes”). Por lo tanto, se puede concluir que la metaheurística es efectiva para los cuantificadores que suponen mayor cobertura espacial (los más específicos).

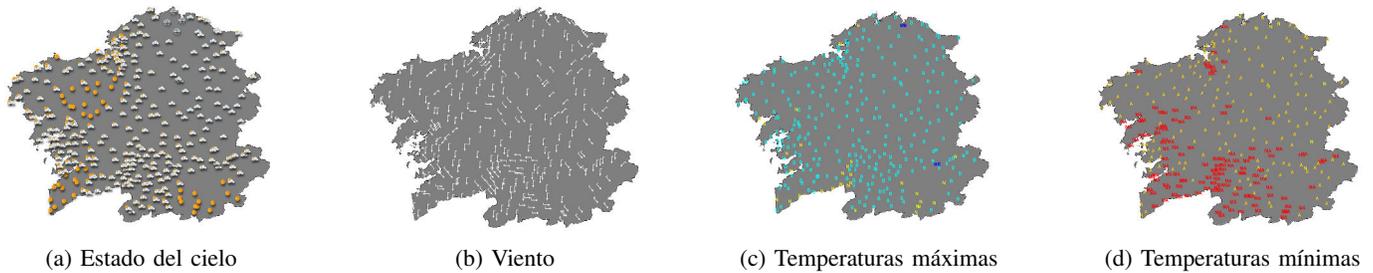


Figura 2: Mapas que definen el estado meteorológico del 15 de septiembre de 2017 a las 17:00 descrito en IV y V.

Por último, hemos evaluado la eficacia de la metaheurística, comparando la calidad de la solución final frente a la solución inicial. Aquí se observa que la media de mejora de las soluciones es del 25 % para cinco ejecuciones realizadas.

## VII. CONCLUSIONES

En este trabajo hemos presentado una aproximación basada en fuerza bruta para la generación de descripciones lingüísticas compuestas de sentencias cuantificadas de tipo I y temple simulado para las de tipo II. Dichas descripciones se generan a partir de datos meteorológicos de observación, sobre un conjunto de variables lingüísticas tanto *crisp* como borrosas, entre las que destacan la inclusión de referencias geográficas. Hemos comparado las sentencias obtenidas con mapas para comprobar si eran representativas. Además, para el caso de las sentencias tipo II, se ha evaluado que la metaheurística genera entre el 25 % y el 75 % de las descripciones de mayor calidad de entre todas las posibles. La metaheurística también resulta efectiva, ya que la calidad de la solución final frente a la inicial mejora en un 25 % en promedio.

Como trabajo futuro, ampliaremos el modelo para nuevas metaheurísticas que puedan compararse en cuanto a rendimiento y calidad de las descripciones generadas.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía y Competitividad (proyectos TIN2014-56633-C3-1-R y TIN2017-84796-C2-1-R) y la Consellería de Educación de la Xunta de Galicia (proyectos GRC2014/030 y Acreditación 2016-2019, ED431G/08"). Todos los proyectos fueron cofinanciados por el programa FEDER. A. Ramos-Soto agradece la financiación de la Consellería de Cultura, Educación e Ordenación Universitaria" (Beca Postdoctoral ED481B 2017/030).

## REFERENCIAS

- [1] A. Gatt and E. Krahrmer, "Survey of the state of the art in natural language generation: Core tasks, applications and evaluation," *Journal of Artificial Intelligence Research*, vol. 61, pp. 65–170, 2018.
- [2] E. Reiter, "An architecture for data-to-text systems," in *Proceedings of the Eleventh European Workshop on Natural Language Generation*. Association for Computational Linguistics, 2007, pp. 97–104.
- [3] N. Marín and D. Sánchez, "On generating linguistic descriptions of time series," *Fuzzy Sets and Systems*, vol. 285, pp. 6–30, 2016.
- [4] L. A. Zadeh, "A prototype-centered approach to adding deduction capability to search engines—the concept of protoform," in *Intelligent Systems, 2002. Proceedings. 2002 First International IEEE Symposium*, vol. 1. IEEE, 2002, pp. 2–3.
- [5] A. Ramos-Soto, A. J. Bugarin, S. Barro, and J. Taboada, "Linguistic descriptions for automatic generation of textual short-term weather forecasts on real prediction data," *IEEE Transactions on Fuzzy Systems*, vol. 23, no. 1, pp. 44–57, 2015.
- [6] P. J. Van Laarhoven and E. H. Aarts, "Simulated annealing," in *Simulated annealing: Theory and applications*. Springer, 1987, pp. 7–15.
- [7] MeteoGalicia: servicio de datos de observación en tiempo real. (2017). [Online]. Available: <http://servizos.meteogalicia.gal/rss/observacion/observacionConcellos.action>
- [8] J. Bateman and M.Zock. NLG systems wiki. (2017). [Online]. Available: <http://nlg-wiki.org/systems/>
- [9] A. Ramos-Soto, A. Bugarín, and S. Barro, "On the role of linguistic descriptions of data in the building of natural language generation systems," *Fuzzy Sets and Systems*, vol. 285, pp. 31–51, 2016.
- [10] F. Portet, E. Reiter, A. Gatt, J. Hunter, S. Sripada, Y. Freer, and C. Sykes, "Automatic generation of textual summaries from neonatal intensive care data," *Artificial Intelligence*, vol. 173, no. 7-8, pp. 789–816, 2009.
- [11] J. Kacprzyk and S. Zadrozny, "Computing with words is an implementable paradigm: fuzzy queries, linguistic data summaries, and natural-language generation," *IEEE Transactions on Fuzzy Systems*, vol. 18, no. 3, pp. 461–472, 2010.
- [12] A. van der Heide and G. Triviño, "Automatically generated linguistic summaries of energy consumption data," in *Intelligent Systems Design and Applications, 2009. ISDA'09. Ninth International Conference on*. IEEE, 2009, pp. 553–559.
- [13] J. Kacprzyk and A. Wilbik, "Using fuzzy linguistic summaries for the comparison of time series: an application to the analysis of investment fund quotations," in *IFSA/EUSFLAT Conf.*, 2009, pp. 1321–1326.
- [14] D. Sanchez-Valdes, L. Eciolaza, and G. Trivino, "Linguistic description of human activity based on mobile phone's accelerometers," in *IWAAL*. Springer, 2012, pp. 346–353.
- [15] A. Alvarez-Alvarez and G. Trivino, "Linguistic description of the human gait quality," *Engineering Applications of Artificial Intelligence*, vol. 26, no. 1, pp. 13–23, 2013.
- [16] R. M. Castillo-Ortega, N. Marín, and D. Sánchez, "A Fuzzy Approach to the Linguistic Summarization of Time Series," *Journal of Multiple-Valued Logic & Soft Computing*, vol. 17, 2011.
- [17] R. Castillo-Ortega, N. Marín, D. Sánchez, and A. G. Tettamanzi, "Linguistic summarization of time series data using genetic algorithms," in *EUSFLAT*, vol. 1, no. 1. Atlantis Press, 2011, pp. 416–423.
- [18] C. A. Donis-Díaz, R. Bello, and J. Kacprzyk, "Using ant colony optimization and genetic algorithms for the linguistic summarization of creep data," in *Intelligent Systems' 2014*. Springer, 2015, pp. 81–92.
- [19] T. Altıntop, R. R. Yager, D. Akay, F. E. Boran, and M. Ünal, "Fuzzy linguistic summarization with genetic algorithm: An application with operational and financial healthcare data," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 25, no. 04, pp. 599–620, 2017.
- [20] R. Tavakkoli-Moghaddam, M.-B. Aryanezhad, N. Safaei, and A. Azaron, "Solving a dynamic cell formation problem using metaheuristics," *Applied Mathematics and Computation*, vol. 170, no. 2, pp. 761–780, 2005.
- [21] S.-W. Lin, J. Gupta, K.-C. Ying, and Z.-J. Lee, "Using simulated annealing to schedule a flowshop manufacturing cell with sequence-dependent family setup times," *International Journal of Production Research*, vol. 47, pp. 3205–3217, June 2009.



# Modelado lingüístico y síntesis de series temporales heterogéneas de consumo energético

S. Martínez-Municio\*, L. Rodríguez-Benítez\*, E. Castillo-Herrera\*, J. Giralt-Muiña\*, L. Jiménez-Linares\*

\*Escuela Superior de Informática, Universidad de Castilla-La Mancha, Paseo de la Universidad s/n. 13071. Ciudad Real, España  
{sergio.martinez, luis.rodriquez, ester.castillo, juan.giralt, luis.jimenez}@uclm.es

**Resumen**—En la actualidad, gracias a la presencia de sensores o al auge de tecnologías propias del *internet de las cosas*, podemos monitorizar y registrar los consumos energéticos obtenidos en los edificios a lo largo del tiempo. Mediante un análisis efectivo de estos datos que capturen los patrones de consumo, se pueden conseguir reducciones significativas de los mismos, contribuyendo a su sostenibilidad. En este trabajo proponemos un marco de trabajo a partir del cual definir modelos que capturen esta casuística, haciendo acopio de un conjunto de series temporales de consumo eléctrico. El objetivo de estos modelos es obtener un resumen lingüístico que describa en lenguaje natural cual es la situación consumista de un edificio o conjunto de edificios en un periodo temporal concreto. La definición de estas descripciones se ha resuelto mediante resúmenes lingüísticos difusos, y como novedad en este campo, proponemos una extensión de los mismos que capturen situaciones donde la pertenencia a los conjuntos difusos no resulte muy marcada (i.e. que no supere un cierto valor umbral, como por ejemplo, 0.8), obteniendo una semántica enriquecida. Para la experimentación, se hará uso de datos de consumo energético de una organización educativa sobre los que se definirán los modelos propuestos y se obtendrán los resúmenes lingüísticos asociados a los mismos, para demostrar la capacidad que otorgan estas técnicas a la hora de obtener conclusiones sobre los diferentes escenarios de consumo en términos lingüísticos.

**Palabras Clave**—consumo energético, modelo difuso, resúmenes lingüísticos, series temporales

## I. INTRODUCCIÓN

La energía constituye uno de los pilares fundamentales para el desempeño adecuado de las actividades imperantes en la sociedad actual. De acuerdo con la Agencia de la Energía [1], los edificios representan el ámbito de mayor consumo energético, lo que conlleva a una responsabilidad directa en un tercio de las emisiones mundiales de dióxido de carbono. Del mismo modo, se ha reportado que los edificios operan de manera ineficiente [2] y por lo tanto, poder entender los patrones de consumo de los mismos resulta de especial interés para optimizar los recursos de las organizaciones, tanto económicos como de uso de la energía, y ser más sostenibles desde el punto de vista medioambiental [3]. En la actualidad, gracias a las tecnologías existentes así como al auge de otras nuevas, como los sensores inteligentes o redes complejas que configuran el *internet de las cosas*, junto con el interés cada vez más acuciante por las técnicas de aprendizaje máquina [4], se dispone de una cantidad de datos sin precedentes que permiten obtener un conocimiento detallado del uso que se está haciendo de la energía en un instante temporal dado en

términos cuantitativos; sin embargo, resulta fundamental incorporar modelos que caractericen estos patrones de consumo energético en términos cualitativos, de modo que permitan aumentar su expresividad mediante descripciones breves en lenguaje natural con el propósito de planificar políticas que contribuyan a una mayor sostenibilidad de los edificios en un marco de revisión y ejecución continua. Dichas descripciones vendrán dadas por medio de resúmenes lingüísticos, ya que han demostrado su utilidad en diferentes ámbitos, como a la hora de describir el tráfico [5] o evaluar la calidad de la forma de andar de las personas [6]. Estos resúmenes están basados en la propuesta de Yager [7], quien proporciona una definición formal basada en el concepto de protoformas introducido por Zadeh [8]:

$$Q[R]y \text{ are } P \quad (1)$$

donde  $y$  es un objeto caracterizado por un atributo con un dominio finito;  $Q$  y  $R$  (opcional) son cuantificadores, que llevan asociado un valor lingüístico definido sobre el dominio del atributo de  $y$ , y  $P$  un resumen que lleva asociado otro valor lingüístico. Además, se han realizado propuestas de generación automática de descripciones lingüísticas alineadas con la temática de este trabajo, donde la principal diferencia radica en que generan dichas descripciones partiendo de las series temporales de un día, sin definir un modelo previo que segmente dichos datos temporales en patrones de consumo [9].

La estructura del trabajo es la siguiente: en la Sección II se introducen los conceptos de modelo de edificio y organizacional, como principales abstracciones de caracterización de consumos, así como la definición de resumen lingüístico. En la Sección III se estudia la validez de los modelos definidos en términos lingüísticos. Una extensión de los resúmenes clásicos que aumenta las capacidades semánticas de los mismos es presentada en la Sección IV, mientras que en la Sección V se lleva a cabo la experimentación mediante la aplicación de los modelos definidos sobre datos de consumo real. Finalmente, la Sección VI presenta las conclusiones obtenidas y establece futuras líneas de trabajo.

## II. DEFINICIÓN DE MODELOS

Se propone la definición de modelos para caracterizar el consumo energético obtenido en grandes instituciones con el fin de obtener en términos lingüísticos las conclusiones

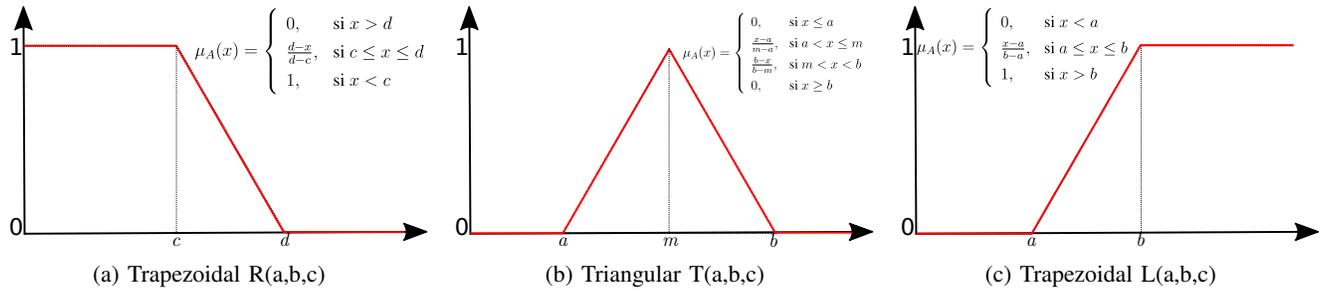


Figura 1: Funciones de pertenencia difusas empleadas

derivadas de los mismos. Para ello, en primer lugar, se define un modelo base (modelo de edificio) que permita categorizar a nivel de edificio cómo ha sido su consumo por medio de una segmentación de los datos que es resuelta con el algoritmo  $k$ -means, para posteriormente, definir un modelo general (modelo de organización) que permita establecer un marco comparativo entre los modelos básicos para saber cómo se han comportado con respecto a los demás y obtener esta conclusión en términos lingüísticos. Como caso de estudio, se emplearán datos de consumo provenientes de una institución educativa española geográficamente distribuida: la Universidad de Castilla-La Mancha (UCLM), que cuenta con un total de 97 edificios repartidos por toda la región. En concreto, se utilizarán datos de consumo por día del año 2016 para la construcción de los modelos, y del año 2017 para la validación de los mismos.

#### II-A. Modelo de Edificio

Un modelo  $M$  de un edificio  $i$  se define como un conjunto de  $k$  grupos que tienen una semántica asociada:

$$M^i = \{G_0, G_1, \dots, G_{k-1}\} \quad (2)$$

donde cada  $G_j$  viene definido por un prototipo,  $c_j$ :

$$G_j = \{c_j\} \quad (3)$$

Cada uno de los modelos de edificio  $M^i$  estará compuesto por dos grupos que caracterizarán los siguientes patrones de consumo: periodos con unos niveles bajos o de no actividad, que se corresponderá con  $G_0$ , y periodos donde existe una actividad relevante, que se corresponderá con  $G_1$ . Por tanto, los términos {no actividad, actividad} representan la semántica asociada a los grupos del modelo de edificio  $M^i$ . De este

Tabla I: Modelos de Edificio de la UCLM - Año 2016

		Modelos definidos	
		$G_0$	$G_1$
Edificios	0	500.44	1215.19
	1	570.23	1213.66
	...		
	95	276.31	1994.66
	96	211.07	406.82

modo, en la Tabla I aparecen recogidos un subconjunto de los diferentes modelos de edificio que han sido generados, donde

cada columna, representa la caracterización del consumo como no actividad ( $G_0$ ) y actividad ( $G_1$ ) respectivamente, y cada fila el edificio en cuestión. Así, por ejemplo, tenemos que el modelo para el edificio 95 quedaría formalizado como:  $M^{95} = \{276.31, 1994.66\}$ , de manera que, si se dispone del consumo real  $x$  para un día concreto, podemos saber cómo ha sido dicho consumo de acuerdo a su modelo, es decir, obtener su categoría semántica (caracterización).

#### II-B. Modelo de Organización

Un modelo organizacional es un modelo de modelos compuesto por cada uno de los sub-modelos de edificio  $M^i$  que queda definido como:

$$O = \left\{ \begin{array}{l} O_{G_0} = \{M_{G_0}^0, M_{G_0}^1, \dots, M_{G_0}^{|M|}\} \\ O_{G_1} = \{M_{G_1}^0, M_{G_1}^1, \dots, M_{G_1}^{|M|}\} \\ \vdots \\ O_{G_k} = \{M_{G_k}^0, M_{G_k}^1, \dots, M_{G_k}^{|M|}\} \end{array} \right\} \quad (4)$$

donde cada  $O_{G_j}$  se refiere al conjunto de modelos de edificio  $M_{G_j}^i$  que caracteriza cada patrón de consumo conforme a lo expuesto en el apartado anterior. Así pues, haciendo uso de (4), definimos el modelo organizacional para la UCLM como:

$$O_{UCLM} = \left\{ \begin{array}{l} O_{G_0} = \{M_{G_0}^0, M_{G_0}^1, \dots, M_{G_0}^{96}\} \\ O_{G_1} = \{M_{G_1}^0, M_{G_1}^1, \dots, M_{G_1}^{96}\} \end{array} \right\} \quad (5)$$

donde  $O_{G_0}$  vendrá dado por el dominio formado por todos los prototipos de los modelos de edificio  $M^i$  correspondientes a la semántica de no actividad:

$$Dom(O_{G_0}) = \{500.44, 570.23, \dots, 211.07\} \quad (6)$$

y  $O_{G_1}$  por los de la semántica de actividad:

$$Dom(O_{G_1}) = \{1215.29, 1213.66, \dots, 406.82\} \quad (7)$$

Partiendo de este modelo de organización  $O_{UCLM}$ , en el siguiente apartado se discutirá la obtención de los resúmenes lingüísticos basados en técnicas difusas que describirán el comportamiento consumista de la organización.



## II-C. Caracterización lingüística

La caracterización lingüística será realizada en base a (1), donde  $y$  será un sintagma significativo,  $R$  vendrá dado por la semántica asociada al modelo, y  $P$  será definido en términos difusos. Un caso especial ocurre con  $Q$ , pues será tratado de manera conjunta con  $y$  y no como un modificador independiente con el que evaluar la sentencia completa (i.e. obtener el grado de verdad de la frase cuantificada lingüísticamente). De esta manera, (1) puede ser simplificada a la siguiente forma:

$$[R]y \text{ are } P \quad (8)$$

La formalización del resumen  $P$  se lleva a cabo haciendo uso de una variable lingüística,  $\mathcal{L}_v$ , que está definida mediante  $n$  conjuntos difusos ( $S'$ ) que configuran una partición difusa del dominio cuyo universo de discurso viene dado por el conjunto de todos los prototipos que conforman cada dominio del modelo  $O$ :

$$\text{Dom}(\mathcal{L}_v) = \text{Dom}(O_{G_j}) \quad (9)$$

A su vez, cada conjunto difuso de  $\mathcal{L}_v$  queda definido mediante una función de pertenencia compuesta por tres parámetros  $P_r$ , que representan el valor del percentil  $r$ , pues permiten conocer el posicionamiento de cada edificio  $i$  en lo que a consumo se refiere, con respecto al total de la organización. En la Fig. 1 se muestran las funciones de pertenencia consideradas para la definición de los valores de  $\mathcal{L}_v$ .

$$\mathcal{L}_v = \{S'_0, S'_1, \dots, S'_m\} \quad (10)$$

Dado que el modelo  $O$  está compuesto de tantos dominios como grupos tengan los modelos de edificios que lo conforman, es necesario identificar el dominio de  $O$  al que pertenece un consumo dado  $x$  de un edificio específico  $i$  para poder aplicar la variable lingüística  $\mathcal{L}_v$  en las magnitudes adecuadas. Para ello, partiendo del modelo de edificio  $M^i$  que categoriza el consumo de un edificio  $i$ , obtenemos el grupo semántico al que pertenece dicho consumo  $x$  a través de la siguiente fórmula:

$$\arg \min \text{dist}(x, G_j) \quad (11)$$

donde  $\text{dist}(x, G_j)$  es una medida de distancia que cuantifica la similitud entre el consumo  $x$  y el prototipo del grupo  $G_j$ , típicamente la euclídea. Sabiendo el grupo semántico al que pertenece  $x$ , podemos obtener el dominio de  $O$  adecuado y aplicar la variable lingüística  $\mathcal{L}_v$  para obtener la etiqueta lingüística que definirá el resumen  $P$ , aplicando la operación de la `t-conorma` del máximo. Por lo tanto, si aplicamos estos conceptos al modelo de estudio,  $O_{\text{UCLM}}$ , la caracterización lingüística vendrá dada de acuerdo con (8), donde  $y$  será *consumo*,  $R$  será *actividad* o *no actividad* y  $P$  quedará definido mediante dos variables lingüísticas  $\mathcal{L}_v$ ,  $\mathcal{L}_v^0$  y  $\mathcal{L}_v^1$ , una para cada conjunto de modelos de edificio  $M^i$  que caracterizan los patrones de consumo de actividad y no actividad en  $O_{\text{UCLM}}$ , es decir, para  $O_{G_0}$  y  $O_{G_1}$  respectivamente. Dichas  $\mathcal{L}_v$  son definidas mediante cinco conjuntos difusos haciendo uso de (10), tal y como se aprecia en la Tabla II, donde la única diferencia entre  $\mathcal{L}_v^0$  y  $\mathcal{L}_v^1$  radica en el dominio empleado.

Tabla II: Definición de  $\mathcal{L}_v$  para  $O_{\text{UCLM}}$

Etiqueta	Función de Pertenencia ( $\mu$ )
Insignificante	$R\{P_0, P_{10}, P_{25}\}$
Leve	$T\{P_{10}, P_{25}, P_{50}\}$
Normal	$T\{P_{25}, P_{50}, P_{75}\}$
Grande	$T\{P_{50}, P_{75}, P_{90}\}$
Enorme	$L\{P_{75}, P_{90}, P_{100}\}$

La caracterización lingüística vista hasta ahora es aplicable a la hora de obtener conclusiones acerca de cómo ha sido el consumo obtenido durante el periodo de vigencia del modelo, pero no nos proporciona la información necesaria sobre el error cometido en la estimación del modelo de edificio  $M^i$  para poder concluir sobre la validez o bondad del mismo. Por ello, en la siguiente sección se propondrá un mecanismo que permita la validación de los modelos en términos lingüísticos.

## III. VALIDACIÓN DE MODELOS

En esta sección se propondrá un mecanismo para conocer la validez de cada uno de los modelos de edificio  $M^i$  definidos, así como del modelo organizacional  $O$ , y de este modo saber si los modelos definidos arrojan las conclusiones adecuadas.

### III-A. Validación del Modelo de edificio

En primer lugar, se debe asociar el consumo real  $x$  obtenido en un instante de tiempo en cada edificio  $i$ , con el grupo semántico  $G_j$  del modelo que mejor lo define para obtener el error cometido en la estimación del modelo por día de consumo real. A este grupo semántico lo denominaremos  $\tilde{G}$ , y será el prototipo que mejor describe el consumo real  $x$ . Formalmente,  $\tilde{G}$  viene definido en términos generales mediante la siguiente función  $f$ , que combina los diferentes grados de pertenencia a los distintos grupos que conforman el modelo de edificio  $M^i$ :

$$\tilde{G} = f(\mu_{G_0}(x), \mu_{G_1}(x), \dots, \mu_{G_{k-1}}(x)) \quad (12)$$

donde  $\mu_{G_j} = \text{dist}(x, G_j)$  y el grupo semántico vendrá dado por  $j = \arg \max \{\mu_{G_0}(x), \mu_{G_1}(x), \dots, \mu_{G_{k-1}}(x)\}$ . De este modo, el error obtenido a la hora de catalogar el consumo real  $x$  en uno de los grupos semánticos vendrá dado por:

$$\epsilon = \tilde{G} - x \quad (13)$$

lo que nos proporciona un valor que es independiente de la escala escogida, permitiéndonos comparar el error obtenido para cada grupo semántico  $\tilde{G}$ . Así, para catalogar si dicho error cometido con respecto a la estimación de su modelo de edificio  $M^i$  es significativo, con un nivel de confianza del 95%, consideramos el intervalo definido por  $\pm 2\sigma$ , con  $\sigma$  siendo la desviación típica propia del grupo semántico  $G_j$  al que pertenece el consumo real  $x$ , de modo que:

- Si  $\epsilon > 2\sigma$ , entonces se ha predicho un mayor consumo que el real, y por lo tanto está siendo **sobreestimado**.
- Si  $-2\sigma \leq \epsilon \leq 2\sigma$ , entonces se ha predicho un consumo que se muestra acorde con el real, y por lo tanto está siendo **adecuado**.

- Si  $\epsilon < -2\sigma$ , entonces se ha predicho un menor consumo que el real, y por lo tanto está siendo **subestimado**.

Con el error  $\epsilon$  cometido por cada consumo real  $x$ , el interés ahora se centra en categorizar la significatividad de dicho error a nivel del modelo de edificio  $M^i$ , es decir, si éste se sitúa en los márgenes establecidos como adecuados o si por el contrario, se sitúa en el 5% de las observaciones restantes, con el fin de obtener una descripción lingüística que resuma la validez del modelo estimado. Para ello, emplearemos una variable lingüística  $\mathcal{L}_m$  (Tabla III) compuesta por cinco conjunto difusos, cuyo dominio vendrá dado por la cantidad de observaciones (errores) que encajan en cada categoría descrita anteriormente de acuerdo con la siguiente fórmula:

$$L_j = \frac{|\epsilon_j|}{|\epsilon|} \times 100 \quad (14)$$

donde  $j \in \{\text{sobreestimado}, \text{adecuado}, \text{subestimado}\}$ ,  $|\epsilon_j|$  será la cantidad de errores que encajan en una de las categorías definidas, y  $|\epsilon|$  será la cantidad total de error cometido. Dado

Tabla III: Definición de  $\mathcal{L}_m$  para validar el modelo

Etiqueta	Función de pertenencia ( $\mu$ )
Insignificante	R{0,10,25}
Leve	T{10,25,50}
Normal	T{25,50,75}
Grande	T{50,75,90}
Enorme	L{75,90,100}

que se tienen tres categorías: *sobreestimado*, *adecuado* y *subestimado*, la descripción lingüística que resuma de manera global la validez del modelo de edificio  $M^i$ , vendrá dada por la categoría cuyo  $L_j$  sea máximo. Así pues, aplicando (8), el resumen lingüístico vendrá dado por:  $y$ , que será la categoría donde  $L_j$  es máximo, y  $P$ , que será la etiqueta lingüística de  $\mathcal{L}_m$  asociada a la categoría  $j$ .

### III-B. Validación del Modelo de organización

Los conceptos vistos en los modelos de edificio pueden ser extendidos para determinar la bondad o validez del modelo organizacional  $O$ . Para ello, hay que realizar una agregación de cada una de las categorías: *subestimado*, *adecuado* y *sobreestimado* para cada modelo de edificio  $M^i$  que componen el metamodelo  $O$  y aplicar la misma variable lingüística  $\mathcal{L}_m$  que en los modelos de edificio  $M^i$ . Dicha agregación,  $L_j$ , viene definida por la siguiente ecuación:

$$L'_j = \frac{\sum L_j}{|L_j|} \quad (15)$$

y al igual que en el caso anterior, la descripción lingüística que resuma de manera global la validez del modelo organizacional  $O$ , vendrá dada por la categoría cuyo  $L'_j$  sea máximo. De este modo, aplicando nuevamente (8), el resumen lingüístico vendrá dado por:  $y$ , que será la categoría donde  $L'_j$  es máximo,  $R$  que será el sintagma *organizacional* para distinguirlo del caso anterior, y  $P$ , que será la etiqueta lingüística de  $\mathcal{L}_m$  asociada a la categoría  $j$ .

A lo largo de esta sección, se ha propuesto un método que permite evaluar cada modelo propuesto gracias al uso de resúmenes lingüísticos difusos. El empleo de conjuntos difusos para su definición, brinda la posibilidad de trabajar con límites poco definidos, de modo que la conclusión derivada de los mismos puede hacer uso con *cierto nivel de pertenencia* de varios de estos conjuntos. Cuando se produce esta casuística, los resúmenes lingüísticos basados en (8) no resultan lo suficientemente expresivos como para poner de manifiesto dicha situación. Por ello, en la siguiente sección introducimos un nuevo concepto de resumen extendido que permite expresar en términos lingüísticos conclusiones cuyos niveles de pertenencia difusa no resulten muy marcados.

## IV. RESÚMENES EXTENDIDOS

Los resúmenes lingüísticos deben poseer la suficiente capacidad expresiva como para no enmascarar u ocultar información que induzcan a conclusiones inexactas. Para tratar de capturar esta casuística, proponemos una modificación sobre la definición dada en (8), permitiendo la adición de un cuantificador absoluto (*cercano a, próximo a...*) [10],  $W$ , al resumen  $P$ , dando lugar a un resumen extendido  $P'$ :

$$P' = WP \quad (16)$$

de modo que es capaz de modelar la descripción lingüística en términos de dos etiquetas lingüísticas con un *nexo* que le proporciona la semántica adecuada. El criterio para discernir si resulta necesario la adición del cuantificador  $W$  al resumen  $P$  para obtener una descripción que capture este tipo de casuísticas en términos lingüísticos vendrá dado por un umbral de pertenencia  $\delta$  asociado a cada conjunto difuso, de modo que: si el valor de pertenencia  $\mu$  es inferior a dicho umbral, por ejemplo  $\delta = 67\%$ , entonces es necesario emplear un resumen extendido  $P'$ ; en caso contrario, un resumen  $P$  clásico resulta suficiente. De este modo, la definición dada en (8) quedaría como sigue:

$$[R]y \text{ are } P' \quad (17)$$

## V. RESULTADOS EXPERIMENTALES

En esta sección se prueba la capacidad expresiva que proporcionan los resúmenes lingüísticos a la hora de resumir el estado relativo al consumo energético en una organización, que como se mencionó en la Sección II, será la Universidad de Castilla-La Mancha. Para ello, se emplearán datos de consumo diario del año 2017 para el edificio 62, cuya área de desempeño es docente e investigadora, en el cual destacamos un primer periodo de no actividad, correspondiente al periodo vacacional de Semana Santa, y otro segundo de actividad, correspondiente a un periodo lectivo, seleccionando un día cualesquiera de cada periodo con los que formalizar los resúmenes lingüísticos:  $x_{na} = 1203.42$  y  $x_a = 2036.24$ .

### V-A. Caracterización del consumo respecto a $M^{62}$

De acuerdo a (2), el modelo de edificio viene dado por:

$$M^{62} = \{1070.84, 1563.12\}$$



mientras que el modelo de la organización  $O_{UCLM}$  es el mismo que (4). Para obtener la caracterización lingüística asociada a los consumos de no actividad ( $x_{na}$ ) y actividad ( $x_a$ ), en primer lugar definimos la variable lingüística  $\mathcal{L}_v$  con la que formalizar el resumen lingüístico, cuya definición aparece en la Tabla IV. Acto seguido, se identifica el dominio de  $O_{UCLM}$

Tabla IV: Definición de  $\mathcal{L}_v$  para  $O_{UCLM}$

Etiqueta	Función de Pertenencia ( $\mu$ )
Insignificante	$R\{P_0, P_{10}, P_{25}\}$
Leve	$T\{P_{10}, P_{25}, P_{50}\}$
Normal	$T\{P_{25}, P_{50}, P_{75}\}$
Grande	$T\{P_{50}, P_{75}, P_{90}\}$
Enorme	$L\{P_{75}, P_{90}, P_{100}\}$

sobre el que aplicar la variable lingüística  $\mathcal{L}_v$  para cada uno de los consumos haciendo uso de (11):

$$\arg \min\{dist(1203.42, 1070.84), dist(1203.42, 1563.12)\} = 0$$

$$\arg \min\{dist(2036.24, 1070.84), dist(2036.24, 1563.12)\} = 1$$

lo que nos indica que para  $x_{na}$ , su grupo semántico se corresponde con  $G_0$ , y que para  $x_a$  es  $G_1$ , algo lógico si atendemos a su modelo de edificio. Sabiendo los grupos semánticos de  $x_{na}$  y  $x_a$ , se concluye que el dominio de  $O_{UCLM}$  sobre el que aplicar  $\mathcal{L}_v$  para cada caso son los definidos en (6) y (7) respectivamente. De este modo, obtenemos la pertenencia de  $x_{na}$  y  $x_a$  a cada conjunto difuso definido en  $\mathcal{L}_v$ , y mediante la t-conorma del máximo, se obtiene el conjunto al que pertenece  $x_{na}$ :

$$\begin{aligned} \max\{\mu_{insignificante}(x) = 0, \mu_{leve}(x) = 0, \\ \mu_{normal}(x) = 0, \mu_{grande}(x) = 0, \\ \mu_{enorme}(x) = 1\} = \mu_{enorme}(x) \end{aligned}$$

y  $x_a$ :

$$\begin{aligned} \max\{\mu_{insignificante}(x) = 0, \mu_{leve}(x) = 0, \\ \mu_{normal}(x) = 0, \mu_{grande}(x) = 0, \\ \mu_{enorme}(x) = 1\} = \mu_{enorme}(x) \end{aligned}$$

Una vez se dispone del conjunto difuso al que pertenece el consumo, ya se puede formalizar el resumen lingüístico de acuerdo a (8). Para el caso del consumo de no actividad,  $x_{na}$ , se tiene que:

«el consumo está siendo *enorme*»

lo cual es debido a que el edificio seleccionado posee un centro de datos que está funcionando continuamente, y para el caso del consumo de actividad,  $x_a$ , se tiene que:

«el consumo está siendo *enorme*»

lo cual es debido a un pico de consumo, ya sea por ser un día veraniego, con el consiguiente consumo en los sistemas de aire acondicionado, o acumulación de horas lectivas en ese periodo.

## V-B. Comparación de $M^{62}$ respecto a $O_{UCLM}$

El experimento anterior proporciona información sobre el consumo obtenido por el edificio 62 comparado con la estimación resuelta por su modelo de edificio  $M^{62}$ . Sin embargo, también es posible obtener cómo se sitúa dicho modelo de edificio  $M^{62}$  con respecto al modelo de la organización  $O_{UCLM}$ . Para ello, debemos seleccionar el prototipo del modelo de edificio que se quiere comparar respecto al modelo organizacional. Si se selecciona  $G_0 = 1070.84$ , empleando la misma variable lingüística  $\mathcal{L}_v$  usando como dominio el definido en (6), tenemos que el conjunto difuso al que pertenece  $G_0$ , aplicando la t-conorma del máximo es:

$$\begin{aligned} \max\{\mu_{insignificante}(x) = 0, \mu_{leve}(x) = 0, \\ \mu_{normal}(x) = 0, \mu_{grande}(x) = 0, \\ \mu_{enorme}(x) = 1\} = \mu_{enorme}(x) \end{aligned}$$

mientras que si se selecciona  $G_1 = 1563.12$ , usando  $\mathcal{L}_v$  sobre el dominio definido en (7), tenemos que el conjunto difuso al que pertenece  $G_1$ , aplicando la t-conorma del máximo es:

$$\begin{aligned} \max\{\mu_{insignificante}(x) = 0, \mu_{leve}(x) = 0, \\ \mu_{normal}(x) = 0, \mu_{grande}(x) = 0.49, \\ \mu_{enorme}(x) = 0.51\} = \mu_{enorme}(x) \end{aligned}$$

de modo que los resúmenes asociados son, para el caso de  $G_0$ :

«el consumo de *no actividad* está siendo *enorme*»

y para el caso de  $G_1$ :

«el consumo de *actividad* está siendo *enorme*»

lo que nos sugiere que el edificio seleccionado es de los que más consumen de toda la Universidad, tanto en periodos donde no existe gran actividad docente o investigadora, como en periodos donde sí la hay. Destacar que para el caso de  $G_1$ , hubiese sido más adecuado emplear un resumen extendido de acuerdo a (17), dándonos como resultado:

«el consumo de *actividad* está siendo *grande con tendencia a enorme*»

## V-C. Validación de Modelos

En este apartado llevaremos a cabo la validación del modelo de edificio  $M^{62}$  y el de la organización  $O_{UCLM}$ . Para el primer caso es necesario calcular el error  $\epsilon$  cometido a la hora de estimar el modelo  $M^{62}$ . Por cada día de consumo del año 2017, se debe obtener el grupo semántico  $\tilde{G}$  de su modelo al que pertenece,  $M^{62}$ , para poder calcular dicho error de acuerdo a (12) y (13) respectivamente. Por ejemplo, utilizando los datos de  $x_{na}$  y  $x_a$  del experimento anterior, se tiene que,  $\tilde{G}_{na} = G_0 = 1070.84$  y  $\tilde{G}_a = G_1 = 1563.12$ , por lo que los errores obtenidos en esos días concretos son:  $\epsilon_{na} = 1070.84 - 1203.42 = -132.58$  y  $\epsilon_a = 1563.12 - 2036.24 = -473.12$ . Una vez se tienen todos los errores

$\epsilon$  cometidos en la estimación, el siguiente paso consiste en categorizar su significatividad a nivel de  $M^{62}$  aplicando la variable lingüística  $\mathcal{L}_m$  definida en la Tabla III, donde el  $L_j$  para cada categoría junto con la pertenencia asociada a cada conjunto difuso de  $\mathcal{L}_m$  identificada viene expresada en la Tabla V.

Tabla V: Definición de  $\mathcal{L}_m$  para validar el modelo

Sobreestimado		Adecuado		Subestimado		
$L_j$	$\mu$	$L_j$	$\mu$	$L_j$	$\mu$	
0 %	<b>1</b>	89 %	0	11 %	<b>0.9</b>	<b>Insignificante</b>
	0		0		0.1	<b>Leve</b>
	0		0		0	<b>Normal</b>
	0		0		0	<b>Grande</b>
	0		<b>1</b>		0	<b>Enorme</b>

Luego como el valor de  $L_{\text{adecuado}}$  resulta ser máximo, con una pertenencia total a la etiqueta enorme, podemos concluir que:

«el modelo resulta adecuado de manera enorme»

o lo que es lo mismo, que el modelo  $M^{62}$  captura correctamente los patrones de consumo subyacentes y nos arroja estimaciones que son correctas.

Por otro lado, para validar el modelo  $O_{\text{UCLM}}$ , se agrega cada una de las categorías de acuerdo a (15), cuyo resultado aparece reflejado en la Tabla VI. Aplicando la variable lingüística  $\mathcal{L}_m$

Tabla VI: Pertenencias de  $L_j$  sobre  $\mathcal{L}_m$

counter	$L_{\text{sobre}}$	$L_{\text{adecuado}}$	$L_{\text{sub}}$
0	9 %	91 %	0 %
1	4 %	96 %	0 %
...			
95	13 %	87 %	1 %
96	23 %	77 %	0 %
	<b>9.35 %</b>	<b>87.14 %</b>	<b>3.51 %</b>

sobre cada categoría  $L'_j$  agregada, obtenemos las pertenencias a cada conjunto difuso de  $\mathcal{L}_m$ , cuyos valores se pueden apreciar en la Tabla VII. Así pues, como el valor  $L'_{\text{adecuado}}$

Tabla VII: Pertenencias de  $L'_j$  sobre  $\mathcal{L}_m$

Sobreestimado		Adecuado		Subestimado		
$L'_j$	$\mu$	$L'_j$	$\mu$	$L'_j$	$\mu$	
9 %	<b>1</b>	87 %	0	4 %	<b>1</b>	<b>Insignificante</b>
	0		0		0	<b>Leve</b>
	0		0		0	<b>Normal</b>
	0		0.20		0	<b>Grande</b>
	0		<b>0.80</b>		0	<b>Enorme</b>

resulta ser máximo, con una pertenencia de 0.8 a la etiqueta enorme, podemos concluir que:

«el modelo *organizacional* resulta adecuado de manera enorme»

o lo que es lo mismo, que el modelo  $O_{\text{UCLM}}$  captura correctamente los patrones de consumo encapsulados por cada modelo de edificio que lo conforma, y que por tanto, arroja estimaciones adecuadas.

## VI. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo propone un nuevo enfoque a la hora de analizar y extraer conclusiones a partir de un conjunto de series temporales de datos de consumo energético heterogéneas (i.e. provenientes de múltiples edificios enmarcados en una misma organización), mediante la definición de modelos que resuman en términos lingüísticos difusos la situación consumista de la organización, con el propósito de servir de apoyo a la toma de decisiones de la alta dirección a la hora de acometer políticas energéticas que contribuyan a la configuración de edificios sostenibles. Además, se ha propuesto una extensión de los resúmenes lingüísticos clásicos que permite tratar la casuística donde la conclusión está mejor definida en término de dos etiquetas si el umbral de pertenencia a la mismas no resulta muy marcado. Finalmente, futuras líneas de trabajo deberían estar encaminadas a obtener un aumento del rendimiento del modelo propuesto, ya sea realizando una segmentación más fina de los grupos, o empleando modelos basados en otro tipo de técnicas, como *deep learning*; definir una arquitectura *big data* basada en microservicios que dé soporte a la definición y manipulación de los modelos o incorporar al modelo un sistema de alertas basado en resúmenes lingüísticos.

## AGRADECIMIENTOS

Los autores quieren agradecer al Ministerio de Economía, Industria y Competitividad de España por el apoyo ofrecido mediante el proyecto TIN2015-64776-C3-3-R, cofinanciado por el Fondo Europeo de Desarrollo Regional (FEDER).

## REFERENCIAS

- [1] O. for Economic Co-operation and Development, *Transition to Sustainable Buildings: Strategies and Opportunities to 2050*, ser. Energy technology perspectives. OECD, 2013.
- [2] M. A. Piette, S. K. Kinney, and P. Haves, "Analysis of an information monitoring and diagnostic system to improve building operations," *Energy and Buildings*, vol. 33, no. 8, pp. 783–791, 2001.
- [3] L. Hernández, C. Baladrón, J. M. Aguiar, B. Carro, and A. Sánchez-Esguevillas, "Classification and clustering of electricity demand patterns in industrial parks," *Energies*, vol. 5, no. 12, pp. 5215–5228, 2012.
- [4] J. Patterson and A. Gibson, *Deep Learning: A Practitioner's Approach*. O'Reilly Media, Inc., 2017.
- [5] A. Alvarez-Alvarez, D. Sanchez-Valdes, G. Trivino, Á. Sánchez, and P. D. Suárez, "Automatic linguistic report of traffic evolution in roads," *Expert Systems with Applications*, vol. 39, no. 12, pp. 11293–11302, 2012.
- [6] A. Alvarez-Alvarez and G. Trivino, "Linguistic description of the human gait quality," *Engineering Applications of Artificial Intelligence*, vol. 26, no. 1, pp. 13–23, 2013.
- [7] R. R. Yager, "A new approach to the summarization of data," *Information Sciences*, vol. 28, no. 1, pp. 69–86, 1982.
- [8] L. A. Zadeh, "A computational approach to fuzzy quantifiers in natural languages," *Computers & Mathematics with applications*, vol. 9, no. 1, pp. 149–184, 1983.
- [9] A. van der Heide and G. Triviño, "Automatically generated linguistic summaries of energy consumption data," in *Intelligent Systems Design and Applications, 2009. ISDA'09. Ninth International Conference on*. IEEE, 2009, pp. 553–559.
- [10] L. A. Zadeh, "Fuzzy logic= computing with words," *IEEE transactions on fuzzy systems*, vol. 4, no. 2, pp. 103–111, 1996.



# Generación Automática de Explicaciones en Lenguaje Natural para Árboles de Decisión de Clasificación

B. López-Trigo, Jose M. Alonso, A. Bugarín

Centro Singular de Investigación en Tecnoloxías da Información (CiTIUS),  
Universidade de Santiago de Compostela,

Campus Vida, E-15782, Santiago de Compostela, Spain

Email: bruno.lopez.trigo@rai.usc.es, {josemaria.alonso.moral, alberto.bugarin.diz}@usc.es

**Resumen**—En este trabajo describimos un modelo de explicaciones en lenguaje natural para árboles de decisión para clasificación. Las explicaciones incluyen aspectos globales del clasificador y aspectos locales de la clasificación de una instancia concreta. La propuesta está implementada en el servicio Web de código abierto ExpliClas [1], que en su versión actual opera sobre árboles construidos con Weka y conjuntos de datos con atributos numéricos. Ilustramos la viabilidad de la propuesta con dos casos de ejemplo, donde mostramos paso a paso cómo el modelo explica los respectivos árboles de clasificación.

**Index Terms**—Explicabilidad, Soft Computing, Árboles de decisión para Clasificación, Generación de Lenguaje Natural

## I. INTRODUCCIÓN

La generalización del uso de las nuevas tecnologías ha hecho que hoy trabajemos y vivamos rodeados de sistemas inteligentes [2]. Términos como ciudad inteligente, fábrica, casa, coche o teléfono inteligentes, son cada vez más populares. En realidad, existen multitud de dispositivos dotados de cierta inteligencia que nos asisten en el día a día, muchas veces sin que seamos totalmente conscientes de ello. Mención especial merece el teléfono móvil, que nos ofrece multitud de aplicaciones casi para cualquier cosa que podamos imaginar y va con nosotros a todas partes. Se puede afirmar que, si bien en el pasado vivimos una revolución industrial, ahora estamos viviendo una revolución social impulsada por la Inteligencia Artificial (IA).

Cuando un sistema inteligente toma decisiones que nos afectan (ej. filtrar llamadas, diagnóstico médico, concesión de un préstamo, etc.), surgen multitud de preguntas que deberíamos hacernos [3]: ¿quién es el responsable de las consecuencias colaterales que pudieran derivarse de las decisiones tomadas? ¿cuáles son las consecuencias éticas? ¿puede haber consecuencias legales?

Desde el punto de vista legal, el Parlamento Europeo aprobó una nueva Regulación General de Protección de Datos [4] que entró en vigor el 25 de mayo de 2018. La nueva regulación enfatiza el derecho de los ciudadanos a pedir explicaciones, independientemente de que las decisiones que les afectan sean tomadas por una persona o un programa informático. Esto significa que los ciudadanos pueden pedir a las empresas que

les den explicaciones asociadas a las decisiones tomadas por los sistemas inteligentes que utilizan.

Desde un punto de vista técnico: ¿puede explicarnos la aplicación que tomó una decisión por qué tomó esa decisión y no otra? Para esto, hay básicamente dos opciones [5]: (1) el sistema inteligente está construido siguiendo un modelo interpretable (también llamado de caja blanca) que un operario experto puede analizar y entender a fin de elaborar una explicación; o (2) el sistema está construido siguiendo un modelo explicable que genera explicaciones por sí mismo. La DARPA planteó en 2016 las siguientes cuestiones técnicas [5]: ¿puede una máquina inteligente aprender de forma autónoma a explicar su comportamiento? ¿está preparada la generación actual de sistemas inteligentes para dar explicaciones de forma clara, sin ambigüedades, tanto a públicos especializados como no especializados? Y lanzó el reto de crear una nueva generación de sistemas inteligentes explicables entre 2017 y 2021. El reto fue lanzado inicialmente a universidades y centros de investigación americanos, con énfasis en la creación de equipos multidisciplinares que abordasen no sólo aspectos algorítmicos sino también de implementación y evaluación con personas. Los equipos seleccionados empezaron a trabajar en mayo de 2017 pero a día de hoy sólo hemos encontrado resultados muy preliminares (ej. [6], [7]).

Hasta donde nosotros sabemos, en la práctica, la responsabilidad de generar explicaciones recae directamente en el operario asociado al sistema inteligente, si está disponible para ello [8]. Aunque hay sistemas basados en conocimiento que son interpretables, en los últimos años son cada vez más populares las técnicas de IA para aprendizaje automático y minería de datos, supervisadas y no supervisadas (es decir, con o sin intervención humana). Estos sistemas se están demostrando ciertamente útiles y versátiles, pero la mayoría no suelen tener ninguna capacidad explicativa ni tampoco pueden ser interpretados fácilmente por personas (en cuyo caso se dice que son sistemas de caja negra).

Por tanto, el nuevo marco legal demanda que los expertos en IA desarrollen nuevos algoritmos que proporcionen explicaciones de forma automática.

En este trabajo, presentamos un modelo para la interpre-

tación de uno de los algoritmos de IA más interpretable, como son los árboles de decisión para clasificación, que introduciremos en la Sección II. El generador de explicaciones basado en dicho modelo y la combinación de técnicas de análisis inteligente de datos y generación de lenguaje natural se describe en la Sección III. La Sección IV presenta 2 casos de uso ilustrativos. Finalmente, la Sección V resume las principales conclusiones y apunta líneas de trabajo futuro.

## II. CLASIFICACIÓN CON ÁRBOLES DE DECISIÓN

Dentro del aprendizaje supervisado a partir de conjuntos de datos, los métodos basados en modelos se caracterizan por representar el conocimiento aprendido en algún formalismo de representación que explicita dicho conocimiento. Una ventaja importante de esta aproximación es que, una vez que se dispone del modelo, éste puede aplicarse directamente sobre nuevas instancias (por ejemplo, en problemas de predicción, como la clasificación) sin necesidad de seguir manteniendo los datos de entrenamiento. Los árboles de decisión utilizan como formalismo de representación un árbol donde los nodos representan condiciones sobre los valores de los atributos del conjunto de datos, que se organizan jerárquicamente, y donde las ramas de cada nodo corresponden a posibles valores del atributo. Hay diferentes métodos inductivos [9], [10] para la construcción de un árbol de decisión, pero todos ellos suelen utilizar estrategias “divide y vencerás” que construyen el árbol desde la raíz a las hojas seleccionando en cada nodo intermedio el atributo y la condición que particiona el conjunto de datos de la mejor manera posible, habitualmente en base a criterios de entropía y de maximización de la ganancia de información [11].

En el caso concreto de los árboles de clasificación, los nodos hojas contienen, idealmente, un conjunto de instancias correspondientes a la misma clase. La aplicación para la clasificación de nuevas instancias se inicia evaluando la condición del nodo raíz para los atributos de dicha instancia y continuando el recorrido por las ramas y nodos correspondientes. El proceso de clasificación finaliza cuando se alcanza un nodo hoja, que indica la clase que corresponde a la instancia. En la práctica, la condición de que un nodo hoja contenga únicamente instancias de la misma clase (nodo “puro”) es demasiado restrictiva, con lo que dicha condición se debe relajar dentro de unos márgenes de pureza. Ello da lugar, por otra parte, a que los árboles clasifiquen incorrectamente algunos (idealmente muy pocos) casos, característica que se recoge en la matriz de confusión entre clases.

Nuestro modelo de explicación de árboles de clasificación se basa en estos aspectos que acabamos de comentar. Por un lado, una caracterización global del problema de clasificación y del árbol inducido. Por otro, una explicación del recorrido por el árbol en la tarea de clasificación. Veremos en la siguiente sección estos aspectos en mayor detalle.

## III. MODELO PARA LA GENERACIÓN DE EXPLICACIONES

La generación de texto en Lenguaje Natural (popularmente conocida como NLG por el acrónimo de “Natural Language

Generation”) constituye una línea de investigación destacada en el área de la IA y la Lingüística Computacional [12].

En este trabajo, tomamos como punto de partida la arquitectura NLG más popular, inicialmente propuesta por Reiter y Dale [13], y la Teoría Computacional de Percepciones propuesta por Zadeh [14]. La generación de explicaciones en Lenguaje Natural se hace combinando plantillas y librerías de código abierto para la realización lingüística [15].

Planteamos la explicación de clasificadores mediante árboles de decisión a dos niveles (global y local), tal y como se describe a continuación. Todos los ejemplos utilizados en las siguientes secciones para ilustrar la propuesta se pueden reproducir mediante el servicio web ExpliClas [1].

### III-A. Explicación global de un clasificador

El primer nivel es la explicación que denominamos global, que se orienta a describir el comportamiento general de un árbol de clasificación dado, aprendido a partir de un determinado conjunto de datos. La información que se incluye en la explicación global se refiere esencialmente a características del propio problema de clasificación y su rendimiento. Los datos de entrada para esta explicación provienen del propio conjunto de datos y de la matriz de confusión del clasificador aprendido.

La planificación de la explicación global contiene los elementos que se muestran a continuación:

- **Contextualización del problema**, que enumera las clases del mismo.

**Prototipo:** There are [N] types of beer: [Class1], [Class2], ... and [ClassN].

**Ejemplo:** There are 8 types of beer: Blanche, Lager, Pilsner, IPA, Stout, Barleywine, Porter and Belgian Strong Ale.

- **Fiabilidad del clasificador**, que evalúa el porcentaje global de clasificaciones correctas sobre el conjunto de datos de aprendizaje, incluyendo una valoración cualitativa del mismo de acuerdo con una definición establecida de valores lingüísticos.

**Prototipo:** This classifier is [very reliable / quite confusing / very confusing] because correctly classified instances represent [percentage] %.

**Ejemplo:** This classifier is very reliable because correctly classified instances represent 94.75 %.

- **Confusión del clasificador**, destacando qué clases se ven afectadas en mayor medida por dicha confusión. Aquí se interpreta la matriz de confusión del clasificador como una matriz de adyacencia de un grafo, cuyos ciclos se entienden como posibles caminos cerrados de confusión entre clases. Se toma el camino de mayor



longitud para ser incluido en la explicación. En caso de que el nivel de confusión sea bajo se omitirá esta parte de la explicación. A la hora de enumerar las clases se busca limitar la longitud de la explicación, tratando de forma diferente los casos en que el camino cerrado de confusión es largo (muchas clases confundidas) o corto (número reducido de clases confundidas) de modo que la longitud de la explicación sea lo más corta posible. Así, en el primer caso, se enumeran las clases para las que no hay confusión (expresándolas como excepciones) y en el segundo caso se enumeran las clases para las que hay confusión. En situaciones intermedias, como la del siguiente ejemplo, se citan los casos concretos.

**Prototipo:** There may be some confusion among samples related to [a few / some / most / all] types of [object]. But among all of them [the pair / pairs [[class1]; [class2]] and [[classM-1]; [classM]] [is / are] the most confused.

**Ejemplo:** There may be some confusion among samples related to some types of beer. But among all of them the pair [IPA; Barleywine] is the most confused.

- **Confusión elevada entre clases**, donde se destacan aquellos pares de clases que presenten un elevado nivel de confusión y no estén incluidas en los ciclos anteriores. Al igual que en los ejemplos mostrados previamente, se incluye una valoración lingüística además de la numérica.

**Prototipo:** [On the one hand / On the other hand], the following pairs are [eventually / often / usually] misled: Class [class1] is confused with class [class2] in [percentage]% of cases.

**Ejemplo:** On the one hand, the following pairs are eventually misled: class headlamps is confused with class build wind float in 10.34% of cases.

### III-B. Explicación local de una instancia

El segundo nivel es la explicación local, que se orienta a explicar cuál es el resultado de la clasificación obtenida al aplicar el clasificador sobre una nueva instancia. La información que se incluye en la explicación local se refiere al recorrido por el árbol de clasificación desde la raíz hasta una hoja, determinado por las condiciones que se cumplen en los diferentes nodos del árbol para la instancia que se quiere clasificar. La versión actual del modelo que hemos definido para la generación de explicaciones en lenguaje natural, se aplica únicamente a atributos de tipo numérico, lo que nos permite dar una cierta flexibilidad en la explicación, para

considerar posibles alternativas a la clasificación real. Para ello incluimos una cierta tolerancia en cuanto a los valores umbral de las condiciones, para de este modo contemplar que se puedan dar pequeñas variaciones en el valor de un atributo, que pudieran derivar en una clasificación diferente. Los datos de entrada para la explicación local son la instancia a clasificar, el árbol de clasificación y el valor de tolerancia permitido (por defecto, 5% sobre el valor de cada atributo).

La planificación de la explicación local contiene los siguientes elementos:

- **Descripción de la clase**, donde se expresa cuál es el resultado de la clasificación y un resumen lingüístico de los valores de los atributos que han dado lugar a dicha clasificación. En el resumen se incluyen, para cada atributo  $X$  expresiones del tipo “ $X$  es  $A$ ”, donde  $A$  es un valor lingüístico predefinido.

**Prototipo:** [Object] is type [output class] because its [attribute1] is [lingTerm1Attribute1] ([or [lingTerm2Attribute1]]), its [attribute2] and [attribute3] are [lingTerm1Attribute1...], ... and its [attributeN] is [lingTerm1AttributeN].

**Ejemplo:** Beer is type Porter because its strength is standard and its color is brown.

- **Explicaciones alternativas**, que se construyen en base al umbral de tolerancia mencionado anteriormente. Se ha establecido un margen de tolerancia del 5% para cada una de las condiciones nodo que justifican la clasificación, de modo que se exploran y se incluyen en la explicación las posibles clasificaciones alternativas que se obtendrían en caso de que los valores de los atributos cumplieren las condiciones dentro del margen de tolerancia.

**Prototipo:** However, this [object] may be also [alternativeClass1] because its [alternativeAttribute1] is quite close to the split value ([thresholdValue]). For these specific values, it is [unlikely / quite likely / just as likely] to be [alternativeClass1].

**Ejemplo:** However, this beer may be also Stout because its color is quite close to the split value (30.45). For these specific values, it is just as likely to be Stout.

Por último también se incorporan en la explicación alternativa aquellas clases para las cuales hay un elevado nivel de confusión en general con la clase original. Para ello se tiene en cuenta la matriz de confusión en lo que respecta a las clases implicadas, adoptando por tanto una cierta perspectiva global. Así, si las clases tienen, en general, un

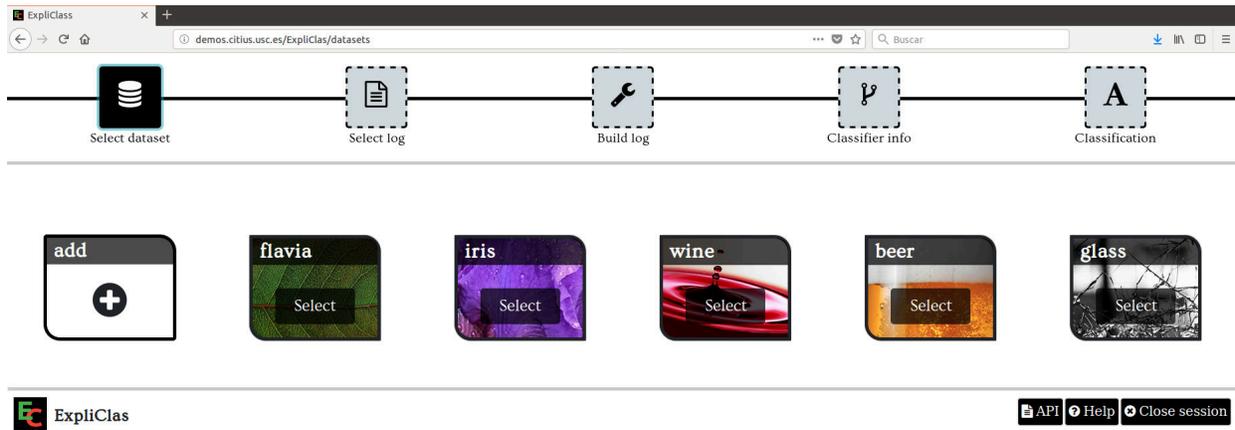


Figura 1. Página de inicio del Servicio Web ExpliClas [1].

elevado nivel de confusión, la explicación enfatiza este aspecto, mientras que si el nivel de confusión es bajo se presentará como un caso de cierta excepción. Mostramos a continuación un ejemplo de esta última situación:

**Prototipo:** But [alternativeClass1] will be an exception because class [outputClass] is confused with [alternativeClass1] only in [percentage]% of cases.

**Ejemplo:** But Stout will be an exception because class Porter is confused with Stout only in 2% of cases.

#### IV. ALGUNOS CASOS DE USO

Una vez descritos los elementos que componen cada explicación, veremos en esta sección dos ejemplos completos, con los que ilustraremos el funcionamiento de nuestra propuesta paso a paso. En ambos casos se aprenden clasificadores utilizando el algoritmo C4.5 [10], en la implementación disponible en Weka (J48) [16], [17]. Tanto los dos ejemplos mostrado (IRIS y FLAVIA), como otros disponibles, se pueden reproducir con el servicio Web ExpliClas [1] (Fig. 1).

##### IV-A. Conjunto de datos IRIS

El conjunto de datos IRIS (uno de los más conocidos del repositorio [18]) está formado por 150 instancias, 4 atributos numéricos y 3 clases. El árbol de clasificación generado por Weka (Fig. 2) está formado por 9 nodos totales, 5 de ellos nodos-hoja que deciden la clasificación y los 4 nodos restantes con las condiciones (comparaciones sobre los valores de los atributos) para decidir la clasificación. Se trata, por tanto, de un árbol simple que utilizaremos como primer ejemplo.

La explicación global generada en este caso es la siguiente:

```
There are 3 types of iris:
Setosa, Virginica and Versicolor.
This classifier is very reliable
because correctly classified
instances represent 96%.
```

```
Petal-Width <= 0.6: 1.0 (50.0)
Petal-Width > 0.6
|   Petal-Width <= 1.7
|   |   Petal-Length <= 4.9: 2.0 (48.0/1.0)
|   |   Petal-Length > 4.9
|   |   |   Petal-Width <= 1.5: 3.0 (3.0)
|   |   |   Petal-Width > 1.5: 2.0 (3.0/1.0)
|   |   Petal-Width > 1.7: 3.0 (46.0/1.0)
```

Figura 2. Árbol de clasificación correspondiente al conjunto de datos IRIS (captura de pantalla de Weka [17]).

La explicación local, para la instancia de la Fig. 3 (Sepal-Length: 5.6, Sepal-Width: 3, Petal-Length: 4.1, Petal-Width: 1.3) es la siguiente:

```
Iris is type Virginica because
its petal-length and petal-width
are medium.
```

En este caso, la explicación consiste en indicar los valores lingüísticos correspondientes a los valores numéricos de los atributos que han dado lugar a la clasificación, tal y como se detalla en la figura.

Sin embargo, si tomamos una instancia cuyos valores sean precisamente los de umbrales de los nodos intermedios (Sepal-Length: 5.6, Sepal-Width: 3, **Petal-Length: 4.9, Petal-Width: 0.6**), la explicación resulta más extensa:

```
Iris is type Setosa because its
petal-width is low.
```

```
However, this iris may be also
Virginica because its petal-width
is quite close to the split value
(0.6).
```

```
It may be also Versicolor because
its petal-width and petal-length
are quite close to the split values
(0.6 and 4.9, respectively). For
these specific values it is just
as likely to be Virginica and
```

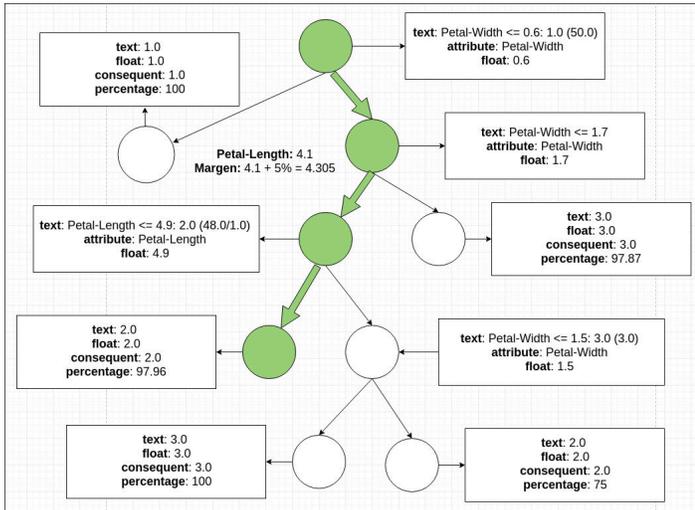


Figura 3. Clasificación de la instancia Sepal-Length: 5.6, Sepal-Width: 3, Petal-Length: 4.1, Petal-Width: 1.3.

Versicolor. But Virginica and Versicolor will be an exception because class Setosa is confused with Virginica and Versicolor only in 2% and 0% of cases, respectively.

En este caso, la clasificación realizada es como clase Setosa. Sin embargo, al ser los valores de la instancia idénticos a los umbrales, y entrar en el rango de la tolerancia establecida del 5%, se consideran como alternativas las dos ramas del nodo raíz y las del nodo que clasifica por longitud. Todas estas alternativas conducen a las clases Virginica y Versicolor. En ambos casos se indica el valor umbral que lo justifica y se valora la situación como que podría ser indistintamente tanto una como otra. Sin embargo, se introduce un matiz de carácter global, puesto que de acuerdo con la matriz de confusión del clasificador, la confusión de la clase Setosa con las clases Virginica y Versicolor es muy poco frecuente:

$$\begin{pmatrix} & \text{Set.} & \text{Virg.} & \text{Vers.} \\ \text{Set.} & 49 & 1 & 0 \\ \text{Virg.} & 0 & 47 & 3 \\ \text{Vers.} & 0 & 2 & 48 \end{pmatrix}$$

IV-B. Conjunto de datos FLAVIA

En esta sección discutimos un caso más realista. FLAVIA<sup>1</sup> es un proyecto de código abierto en el que se abordó la creación de un conjunto de datos para la clasificación automática de hojas en la región de Yangtze Delta (próxima a Shanghai) en China. El conjunto de datos está formado por 1800 muestras de hojas (15 atributos) que corresponden a 32 clases diferentes. Una red neuronal es capaz de clasificar todas las hojas con una tasa de acierto superior al 90% [19]. Sin embargo, la clasificación se basa en un modelo de caja negra que una persona no puede entender. El árbol construido por el

<sup>1</sup><http://flavia.sourceforge.net/>

algoritmo J48 de Weka contiene 449 nodos (225 nodos-rama) y una tasa de acierto de clasificación del 70.44% (considerando 10-fold cross-validation). Se puede apreciar cómo pasar de un modelo de caja negra a un modelo de caja blanca supone en este caso una reducción apreciable en precisión. Además, aunque el modelo generado es de caja blanca, el elevado número de clases, atributos y nodos hace que la interpretación no sea sencilla, incluso para un experto en botánica.

En [20], presentamos los resultados de una encuesta en la que demostramos la utilidad de generar explicaciones en lenguaje natural asociadas a clasificaciones hechas por un conjunto de reglas borrosas aprendidas sobre un subconjunto de los datos de FLAVIA, con 310 instancias, 3 atributos y 5 clases (Fig. 4). De los 15 atributos de partida (que caracterizan propiedades geométricas y morfológicas) seleccionamos sólo los tres (Área, Perímetro y Diámetro) que un experto en botánica consideró útiles a fin de explicar en lenguaje natural el proceso de clasificación; prestando atención únicamente a la forma de la hoja. En esta sección, consideramos el mismo conjunto de datos usado en [20]. La explicación global es la siguiente:

There are 5 types of flavia:  
Aesculus chinensis, Berberis anhweiensis, Cercis chinensis, Phoebe zhennan and Lagerstroemia indica.  
This classifier is very reliable because correctly classified instances represent 90.97%. There may be some confusion among samples related to some types of flavia. But among all of them the pair [Cercis chinensis; Phoebe zhennan] is the most confused.

La matriz de confusión correspondiente (ordenada según las 5 clases de hoja en la Fig. 4) es:

$$\begin{pmatrix} 60 & 1 & 2 & 0 & 0 \\ 0 & 55 & 2 & 1 & 0 \\ 3 & 0 & 63 & 6 & 0 \\ 1 & 0 & 5 & 52 & 2 \\ 0 & 0 & 1 & 4 & 52 \end{pmatrix}$$

El árbol construido en este caso contiene sólo 25 nodos (13 nodos-rama) y una tasa de acierto de clasificación del 90.97% (considerando 10-fold cross-validation).

ExpliClas permite introducir a mano el valor numérico de los atributos cuando el objeto a clasificar no coincide con ninguna de las instancias en el conjunto de datos. Por ejemplo, la explicación local para la hoja en la Fig. 5 sería la siguiente. Nótese que una sencilla comparativa visual entre las figuras 4 y 5 permite verificar cualitativamente la explicación dada.

Flavia is type Cercis chinensis because its area is not very small and its perimeter is small. However, this flavia may be

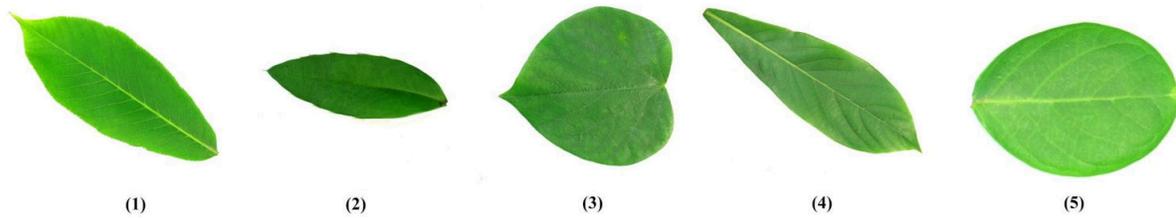


Figura 4. Las 5 clases en la versión reducida de FLAVIA: (1) *Aesculus chinensis*, (2) *Berberis anhwieensis*, (3) *Cercis chinensis*, (4) *Phoebe zhennan*, (5) *Lagerstroemia indica*.



Figura 5. Ejemplo de hoja a clasificar (Área: 349,045, Perímetro: 2.964,304, Diámetro: 666,647).

also *Phoebe zhennan* because its perimeter is quite close to the split value (3,042.19). For these specific values it is just as likely to be *Phoebe zhennan*. But *Phoebe zhennan* will be an exception because class *Cercis chinensis* is confused with *Phoebe zhennan* in 8.33% of cases.

## V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo hemos presentado un modelo para la generación de explicaciones (globales y locales) en lenguaje natural sobre clasificaciones hechas con árboles de decisión con atributos numéricos. El modelo está implementado en el servicio web ExpliClas [1]. Como trabajo futuro, realizaremos una validación exhaustiva del modelo con usuarios reales y refinaremos las explicaciones según la realimentación recibida. Adicionalmente, extenderemos el modelo de explicación para considerar atributos categóricos y algoritmos de clasificación de caja gris, como árboles de decisión borrosos, entre otros.

## AGRADECIMIENTOS

Jose M. Alonso es Investigador Ramón y Cajal (RYC-2016-19802). Este trabajo está financiado por los proyectos TIN2017-90773-REDT (iGLN), TIN2017-84796-C2-1-R (BIGBISC), TIN2014-56633-C3-1-R (BAI4SOW) y TIN2014-56633-C3-3-R (ABS4SOW) (Ministerio de Economía y Competitividad) y GRC2014/030 y “Acreditación 2016-2019, ED431G/08” (Xunta de Galicia), todos con cofinanciación FEDER.

## REFERENCIAS

- [1] B. López-Trigo, J. M. Alonso, and A. Bugarín, “ExpliClas: Web service for the automatic explanation in natural language of classification models in data mining,” 2018, <http://demos.citius.usc.es/ExpliClas/>.
- [2] K. Panetta, “Gartner top 10 strategic technology trends for 2018,” 2017, <https://www.gartner.com/smarterwithgartner/gartner-top-10-strategic-technology-trends-for-2018/>.

- [3] S. Barocas and D. Boyd, “Computing ethics. engaging the ethics of data science in practice,” *Communications of the ACM*, vol. 60, no. 11, pp. 23–25, 2017.
- [4] Parliament and Council of the European Union, “General data protection regulation (GDPR),” 2016, <http://data.europa.eu/eli/reg/2016/679/oj>.
- [5] D. Gunning, “Explainable Artificial Intelligence (XAI),” Defense Advanced Research Projects Agency (DARPA), Arlington, USA, Tech. Rep., 2016, DARPA-BAA-16-53.
- [6] M. T. Ribeiro, S. Singh, and C. Guestrin, “Why should I trust you? explaining the predictions of any classifier,” in *Proceedings of the ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD)*, San Francisco, USA, 2016, pp. 1–10.
- [7] L. A. Hendricks, Z. Akata, M. Rohrbach, J. Donahue, B. Schiele, and T. Darrell, “Generating visual explanations,” in *Proceedings of the European Conference on Computer Vision (ECCV)*, Amsterdam, The Netherlands, 2016, pp. 3–19.
- [8] K. Darlington, “Explainable AI systems: Understanding the decisions of the machines,” 2017, openMind, BBVA Group, <https://www.bbvaopenmind.com/en/explainable-ai-systems-understanding-the-decisions-of-the-machines/>.
- [9] J. Quinlan, “Induction of decision trees,” *Machine Learning*, vol. 1, no. 1, pp. 81–106, 1986.
- [10] J. R. Quinlan, *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers, San Mateo, CA, 1993.
- [11] L. Breiman, J. Friedman, R. Olshen, and C. Stone, *Classification and Regression Trees*, 1st ed. Wadsworth, 1984.
- [12] A. Gatt and E. Kraemer, “Survey of the state of the art in natural language generation: Core tasks, applications and evaluation,” *Journal of Artificial Intelligence Research*, vol. 61, pp. 65–170, 2018.
- [13] E. Reiter and R. Dale, *Building natural language generation systems*. Cambridge University Press, 2000.
- [14] L. A. Zadeh, “A new direction in AI: Toward a computational theory of perceptions,” *Artificial Intelligent Magazine*, vol. 22, no. 1, pp. 73–84, 2001.
- [15] A. Gatt and E. Reiter, “SimpleNLG: a realisation engine for practical applications,” in *Proceedings of the European Workshop on Natural Language Generation (ENLG)*, Athens, Greece, 2009, pp. 90–93.
- [16] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal, *Data Mining: Practical Machine Learning Tools and Techniques*, 4th ed. Morgan Kaufmann, 2016.
- [17] The University of Waikato, “Weka 3: Data Mining Software in Java,” 2018, <https://www.cs.waikato.ac.nz/ml/weka/>.
- [18] The University of California at Irvine, “UCI machine learning repository,” 2018, <https://archive.ics.uci.edu/ml>.
- [19] S. Gang Wu, F. Sheng Bao, E. You Xu, Y.-X. Wang, Y.-F. Chang, and Q.-L. Xiang, “A leaf recognition algorithm for plant classification using probabilistic neural network,” in *IEEE International Symposium on Signal Processing and Information Technology*, 2007, pp. 1–6.
- [20] J. M. Alonso, A. Ramos-Soto, E. Reiter, and K. van Deemter, “An exploratory study on the benefits of using natural language for explaining fuzzy rule-based systems,” in *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Naples, Italy, 2017, pp. 1–6, <http://dx.doi.org/10.1109/FUZZ-IEEE.2017.8015489>.



# Descripción de series de tiempo utilizando Fuzzy Piecewise Linear Segments

Juan Moreno-García, Antonio Moreno-García  
*Universidad de Castilla-La Mancha*  
*Escuela de Ingeniería Industrial*  
 Toledo, España  
 juan.moreno@uclm.es, antmorgarcia@gmail.com

Luis Jimenez-Linares, Luis Rodriguez-Benitez  
*Universidad de Castilla-La Mancha*  
*Escuela Superior de Informática*  
 Ciudad Real, España  
 luis.jimenez@uclm.es, luis.rodriguez@uclm.es

**Abstract**—Es muy frecuente la utilización de series temporales en gran cantidad de ámbitos, siendo necesario la obtención de información lo más detallada posible a partir de estas series. Hay diferentes posibilidades de mostrar esta información, por ejemplo, en forma de representación gráfica. Aunque cada día es más frecuente la necesidad de representar información utilizando el lenguaje natural, es decir, mediante una descripción lingüística. En este trabajo se presenta una técnica para obtener descripciones lingüísticas a partir de series temporales utilizando una representación denominada Fuzzy Piecewise Linear Segments. Se detalla la forma de obtener la información de una serie modelada utilizando esta representación y los pasos necesarios para generar la descripción utilizando plantillas. Finalmente se muestra algunos ejemplos de su uso.

**Index Terms**—Descripción Lingüística, Series de Tiempo, Fuzzy Piecewise Linear Segments, Lógica Difusa

## I. INTRODUCTION

En un gran número de aplicaciones se necesitan las series de tiempo. Usualmente estas series se representan en forma de datos en bruto. Este formato tiene varios problemas siendo el más importante la gran cantidad de memoria necesaria para su almacenamiento. Además, esta representación presenta el problema añadido de que su procesamiento es costoso en tiempo. Por esta razón se han desarrollado otras formas alternativas para almacenar las series de tiempo, lo que permite reducir el consumo de memoria y la ejecución de operaciones más eficientemente. Una de las técnicas más utilizadas se denomina “segmentos lineales a trozos” (Piecewise Linear Segment – PLS) que consiste en la representación de las series utilizando un conjunto de segmentos, donde cada uno de ellos corresponde a un trozo de la serie. Hay diferentes métodos para obtener esta representación en la literatura [1]–[3]. Además, cada día es más frecuente la generación de informes de datos utilizando el lenguaje natural. Esto se conoce como Descripción Lingüística de Datos [4]. Es una línea de investigación que se puede considerar clásica pero que actualmente está teniendo un fuerte auge.

El principal objetivo de este trabajo consiste en diseñar un nuevo método de generación de descripciones lingüísticas de series de tiempo. Muchos de los métodos presentados

en la literatura hacen uso de la lógica difusa para obtener la descripción [4]. Por todo ello, se propone el uso de una representación de series que utiliza la lógica difusa [5] para generar descripciones lingüísticas directamente desde dicha representación. Esta representación se ha denominado *Fuzzy Piecewise Linear Segments* (FPLS) y tiene la ventaja de que recoge la imprecisión creada en el proceso de generación de los segmentos. Cada segmento de PLS se convierte al dominio difuso utilizando las técnicas detalladas en [5].

El documento está estructurado de la siguiente forma. En la Sección II se presenta una breve recopilación de los trabajos más destacados en este ámbito de investigación. En la Sección III se expone la representación FPLS. En la Sección IV se detalla la forma de obtener información de un FPLS y cómo generar las descripciones en base a ésta. Finalmente, la Sección V muestra las conclusiones y trabajos futuros.

## II. ESTADO DEL ARTE

La descripción de series de tiempo (TS) es un campo de investigación con un gran número de publicaciones en los últimos 10 años. Recientemente Marín and Sánchez [4] han publicado un trabajo que recopila las publicaciones más destacadas en la literatura. Estos autores distinguen entre Generación de Lenguaje Natural (Natural Language Generation – NLG) y la Generación de Descripciones Lingüísticas de TS (Generation of Linguistic Descriptions of Time Series – GLiDTS). Se podría afirmar que este trabajo está relacionado con GLiDTS.

En general, la lógica difusa (Fuzzy Logic – FL) es un componente esencial en este tipo de sistemas y ha sido aplicada de diferentes formas. Se presentarán algunos trabajos destacados que utilizan la FL para describir TS y otros que funcionan junto con otras tecnologías. Por ejemplo, algunas propuestas combinan sistemas OLAP [6], diseñados para su utilización en la toma de decisión y aplicados en una amplia variedad de dominios de aplicación, con la FL. En esta línea se encuentra una nueva aproximación que hace uso de particiones jerárquicas difusas del tiempo y la evaluación de sentencias cuantificadas [7], [8]. La descripción final consiste en una colección de este tipo de sentencias. Otro ejemplo es *GALiWeather* [9] que mezcla técnicas de computación de percepciones con estrategias para la descripción lingüística

Supported by the project TIN2015-64776-C3-3-R of the Science and Innovation Ministry of Spain, co-funded by the European Regional Development Fund (ERDF).

de datos junto con un sistema de NLG. El sistema ofrece información sobre el tiempo que es utilizada por la Agencia de Meteorología Gallega. Actualmente, *GALiWeather* es un servicio público ofrecido para la predicción del tiempo.

Otra posibilidad consiste en generar un modelo difuso a partir de la TS y calcular una estructura de alto nivel. Por ejemplo, en [10], [11] se presentó una estructura para modelar los eventos que ocurren en una TS. El modelo final contiene los mínimos y máximos utilizando [11]. Esta estructura también permite la búsqueda de eventos: el resultado obtenido de esta búsqueda genera la descripción lingüística final que está formada por sentencias de texto que son añadidas cuando se identifica un nuevo evento. El sistema necesita un experto en el campo de aplicación.

Otras propuestas consisten en transformar la TS en otra representación y entonces fuzzificarla. Por ejemplo, Kacprzyk et al. [12] propusieron el uso de tendencias identificando segmentos lineales de una TS. Posteriormente representan la serie mediante un conjunto de atributos que caracterizan las tendencias (la pendiente del segmento, la calidad de la aproximación y la longitud de la tendencia). El campo de aplicación que seleccionaron fue la evaluación de un fondo de inversión en un período de tiempo. En otras situaciones la información proviene de diversas fuentes y debe ser agregada apropiadamente obteniendo una nueva representación que se trata utilizando FL [13].

Otras investigaciones crean modelos específicos para generar descripciones lingüísticas. Granular Linguistic Model of Phenomena (GLMP) puede ser clasificado dentro de esta categoría. Alvarez-Alvarez y Triviño [14] introdujeron la aplicación de GLMP para generar descripciones de la calidad de la marcha humana y Sánchez-Valdés y Triviño mejoraron los resultados utilizando una máquina de estados finitos difusa [15]. GLMP ha sido utilizado en aplicaciones de tipo muy diverso.

### III. DESCRIPCIÓN DE FPLS

Una FPLS es un conjunto de segmentos que han sido fuzzificados a partir de los segmentos de una PLS. Para un instante dado ofrecen un número difuso que es el valor de salida. Formalmente, una FPLS está compuesta por un conjunto de segmentos lineales difusos que serán representados como  $fpls_{t_i, t_{i+1}}$ . La Ecuación 1 representa formalmente a una FPLS.

$$FPLS(T) = \{fpls_{t_0, t_1}, fpls_{t_1, t_2}, \dots, fpls_{t_{|FPLS|-1}, t_{|FPLS|}}\} \quad (1)$$

donde cada segmento  $fpls_{t_i, t_{i+1}} = \{m_{t_i, t_{i+1}}, c_{t_i, t_{i+1}}, p_{t_i, t_{i+1}}\}$  siendo  $m_{t_i, t_{i+1}}$  y  $c_{t_i, t_{i+1}}$  la pendiente y la constante de la recta que define el segmento respectivamente, y  $p_{t_i, t_{i+1}}$  el promedio de la tasa de error (Ecuación 2).

$$p_{t_i, t_{i+1}} = \frac{\sum_{k=i}^{i+1} \frac{|fpls_{t_i, t_{i+1}}(t_k) - y_k|}{y_k}}{t_{i+1} - t_i + 1} \quad (2)$$

donde  $t_i$  y  $t_{i+1}$  son los instantes de comienzo y de fin del segmento,  $fpls_{t_i, t_{i+1}}(t_k)$  es el valor del segmento  $fpls_{t_i, t_{i+1}} \in FPLS$  en el instante  $t_k$  e  $y_k$  es el valor de la serie  $Y$  en el instante  $t_k$ .

El promedio de la tasa de error es una medida que calcula la media de la tasa del error para cada segmento utilizando la Ecuación 2.

Cada segmento lineal difuso  $fpls_{t_i, t_{i+1}}$  devuelve un número difuso triangular  $fn_k$  para un instante  $t_k \in \mathbb{R}$ :  $fn_k = fpls_{t_i, t_{i+1}}(t_k)$ . Utilizando estos tres valores, el número difuso de salida  $fn_k$  se puede calcular tomando como entrada un valor  $t_k$ . La Ecuación 3 muestra la forma en que un segmento  $fpls_{t_i, t_{i+1}}$  calcula el número difuso  $fn_k$ .

$$fn_k = \begin{cases} 0 & \text{if } t_k < t_i \\ \text{calcular}(fpls_{t_i, t_{i+1}}, t_k) & \text{if } t_i \leq t_k \leq t_{i+1} \\ 0 & \text{if } t_{i+1} < t_k \end{cases} \quad (3)$$

donde  $\text{calcular}(fpls_{t_i, t_{i+1}}, t_k)$  es una función que calcula  $fn_k^{DOWN}$ ,  $fn_k^{fpls}$  y  $fn_k^{UP}$  que componen el número difuso triangular  $fn_k = \{fn_k^{DOWN}, fn_k^{fpls}, fn_k^{UP}\}$ .

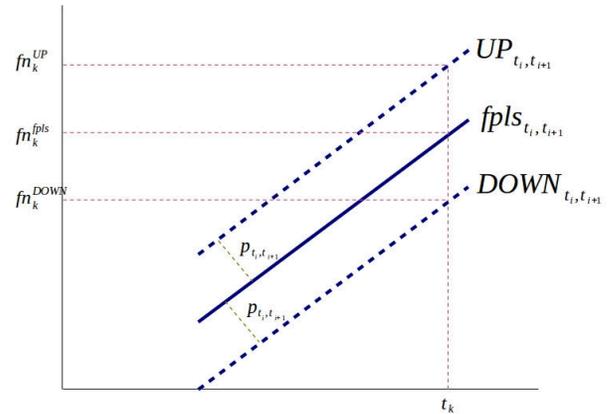


Fig. 1. Procedimiento para el cálculo de  $fn_k$  a partir de un segmento difuso.

Para los valores de  $t_k$  menores que  $t_i$  o mayores que  $t_{i+1}$ , la salida es cero. Para valores entre  $t_i$  y  $t_{i+1}$  se calcula utilizando dos segmentos paralelos con respecto a  $fpls_{t_i, t_{i+1}}$  llamados  $UP_{t_i, t_{i+1}}$  y  $DOWN_{t_i, t_{i+1}}$  (Figura 1).  $p_{t_i, t_{i+1}}$  se necesita para calcular los segmentos  $UP_{t_i, t_{i+1}}$  y  $DOWN_{t_i, t_{i+1}}$ , que están por encima y por debajo en el eje  $Y$  respecto a  $fpls_{t_i, t_{i+1}}$ , es decir:

- $UP_{t_i, t_{i+1}} = (m_{t_i, t_{i+1}} * x) + c_{t_i, t_{i+1}} + p_{t_i, t_{i+1}}$
- $DOWN_{t_i, t_{i+1}} = (m_{t_i, t_{i+1}} * x) + c_{t_i, t_{i+1}} - p_{t_i, t_{i+1}}$

Los valores  $fn_k^{DOWN}$ ,  $fn_k^{fpls}$  y  $fn_k^{UP}$  que definen  $fn_k$  se calculan como el valor de salida de los segmentos lineales  $DOWN_{t_i, t_{i+1}}$ ,  $fpls_{t_i, t_{i+1}}$  y  $UP_{t_i, t_{i+1}}$  para un instante  $t_k$  y en orden creciente, es decir:

- $fn_k^{DOWN} = DOWN_{t_i, t_{i+1}}(t_k)$
- $fn_k^{fpls} = fpls_{t_i, t_{i+1}}(t_k)$
- $fn_k^{UP} = UP_{t_i, t_{i+1}}(t_k)$



TABLE I  
UN FPLS DE EJEMPLO. FUENTE MORENO-GARCIA ET AL. [5]

$fpls_{t_i, t_{i+1}}$	$mt_{i, t_{i+1}}$	$ct_{i, t_{i+1}}$	$pt_{i, t_{i+1}}$
$fpls_{0.0, 17.0}$	-0.0432	0.6786	0.313
$fpls_{17.0, 49.0}$	0.0339	-0.5487	0.5544
$fpls_{49.0, 91.0}$	-0.0249	2.1815	0.4561
$fpls_{91.0, 94.0}$	-0.0007	0.1543	0.0905
$fpls_{94.0, 131.0}$	0.0229	-2.1022	0.4582

Estos valores representan un número difuso triangular simétrico (Symmetric Triangular Fuzzy number – STFNN) con la etiqueta lingüística “aproximadamente  $fn_k$ ” y una función de pertenencia que se muestra en la Ecuación 4.

$$\mu_{fn_k}(y) = \begin{cases} 0 & \text{if } |fn_k^{fpls} - y| > fn_k^{UP} - fn_k^{fpls} \\ 1 & \text{if } y = fn_k^{fpls} \\ \frac{|fn_k^{fpls} - y|}{fn_k^{UP} - fn_k^{fpls}} & \text{if } |fn_k^{fpls} - y| < fn_k^{UP} - fn_k^{fpls} \end{cases} \quad (4)$$

Como el soporte de  $fn_k$  se calcula en base al promedio de la tasa de error para el segmento obtenido, el uso de la media es apropiado para “medir la incertidumbre”, es decir, cuanto mayor es el error, mayor es el soporte del número difuso.

FPLS permite realizar diferentes operaciones. Actualmente están definidas la comparación entre dos FPLSs que representan dos TS o a una subsecuencia de una TS, que conceptual y prácticamente son lo mismo. La idea básica del funcionamiento del método consiste en realizar un conjunto de comparaciones a instantes de tiempo igualmente espaciados sobre las dos FPLS. Los números difusos obtenidos para cada FPLS como salida en cada instante pueden ser comparados mediante operaciones de la lógica difusa, y posteriormente recoger el resultado en un valor que agregue las comparaciones realizadas representando la similitud/disimilitud de ambas FPLS, y por tanto de ambas TS o subsecuencias, según el caso. Para comparar dos STFNN se utilizó una medida que toma el valor del área comprendida entre ellos considerando el valor de los números difusos a comparar.

#### IV. GENERACIÓN DE LAS DESCRIPCIONES

De una FPLS se puede obtener información para generar las descripciones lingüísticas. Esta información se va a clasificar en dos niveles:

- De segmento: a este nivel se pueden generar descripciones lingüísticas que reflejan información sobre las tendencias, dado que un segmento representa una tendencia.
- De FPLS: en este caso se mostrará información de la TS completa o de una parte de ella ya que una FPLS representa una TS.

Primero se presentará la información que se puede obtener a nivel de una tendencia (segmento), más concretamente, se detallará la siguiente:

- Tipo de tendencia: se obtendrá una etiqueta lingüística por segmento que se ha denominado  $type_{i+1}$  y que indica el tipo de tendencia obtenida para el segmento  $i + 1$ . Estará

TABLE II  
CONJUNTO DE ETIQUETAS LINGÜÍSTICAS *TYPE*.

Label	$a$	$b$	$c$	$d$
descendente	$-\infty$	$-\infty$	-0.1	0.0
plana	-0.1	0.0	0.0	0.1
ascendente	0.0	0.1	$\infty$	$\infty$

TABLE III  
CONJUNTO DE ETIQUETAS LINGÜÍSTICAS *POWER*.

Label	$a$	$b$	$c$	$d$
fuerte descenso	-90	-90	-45	-40
descenso	-45	-40	-2	0
llano	-2	0	0	2
ascenso	0	2	40	45
fuerte ascenso	40	45	90	90

en función de la pendiente del segmento que modela. La pendiente de una recta es mayor o menor que 0 si la recta es creciente o decreciente respectivamente. Se distinguirán tres tipos de segmento: descendente, plana y ascendente (Tabla II), aunque se puede redefinir este conjunto de etiquetas para incorporar más grados.  $type_{i+1}$  toma de valor la etiqueta de máxima pertenencia de las de ese conjunto (Ecuación 5).

$$type_{i+1} = argmax_T \mu_T(mt_{i, t_{i+1}}) \forall T \in TYPE \quad (5)$$

- Potencia de la tendencia: vendrá definida por el ángulo del segmento difuso ( $arctan(mt_{i, t_{i+1}})$ ) y para clasificarla se utilizará el conjunto de etiquetas lingüísticas *POWER*. La Ecuación 6 muestra la forma de obtener dicha etiqueta.

$$power_i = argmax_P \mu_P(arctan(mt_{i, t_{i+1}})) \forall P \in POWER \quad (6)$$

$power_i$  se asigna a la etiqueta lingüística  $P \in POWER$  que obtiene el máximo valor de pertenencia para el ángulo del segmento, es decir, la etiqueta que representa mejor el incremento o el decremento del segmento difuso. La Tabla III muestra un conjunto ejemplo que utiliza etiquetas difusas donde el soporte está considerado como el ángulo de la pendiente medido en grados sexagesimales.

- Duración: se definirá un conjunto de etiquetas llamado *LONG* para representar la longitud del segmento. Cada segmento  $fpls_{t_i, t_{i+1}}$  cuenta con sus instantes de inicio

TABLE IV  
CONJUNTO DE ETIQUETAS LINGÜÍSTICAS *LONG*.

Label	$a$	$b$	$c$	$d$
muy corta	0	0	2.5	5
corta	2.5	5	15	20
un poco corta	15	20	30	35
media	30	35	45	50
larga	45	50	55	65
muy larga	55	65	$\infty$	$\infty$

TABLE V  
 CONJUNTO DE ETIQUETAS LINGÜÍSTICAS *LOC*.

Label	a	b	c	d
inicio	0	0	5	10
inicio pasado	5	10	35	40
centro	35	40	60	65
centro pasado	60	65	90	95
final	90	95	100	100

y fin ( $t_i$  y  $t_{i+1}$ ) que permitirán calcular la duración mediante la Ecuación 7.

$$long_i = argmax_L \mu_L(t_{i+1} - t_i) \forall L \in LONG \quad (7)$$

Como puede verse se realiza de forma similar a los casos anteriores. Las etiquetas de *LONG* permitirán indicar el tamaño de los segmentos. La Tabla IV muestra que será utilizado posteriormente.

- Localización: se trata de definir la localización de la tendencia en el tiempo. Para ello se utilizará el instante central de ocurrencia de la tendencia y se fuzzificará utilizando un conjunto de etiquetas lingüísticas denominado *LOC* con un soporte en  $[0\%, 100\%]$  del total de la longitud de la TS descrita. La Ecuación 8 muestra la forma de seleccionar la etiqueta.

$$loc_i = argmax_L \mu_L\left(\frac{p_{cen}}{|TS|}\right) \forall L \in LOC \quad (8)$$

donde  $p_{cen}$  se calcula utilizando la Ecuación 9.

$$p_{cen} = \left(t_i + \frac{t_{i+1} - t_i}{2}\right) * 100 \quad (9)$$

La Tabla V muestra un ejemplo de este conjunto que será utilizado en los ejemplos.

El segundo nivel que se puede realizar la descripción es a nivel de la FPLS completa. Se puede detallar información general como por ejemplo el número de tendencias, la longitud media de cada una de ellas, número de mínimos y máximos locales, localización de éstos, etc. A continuación se detallará la forma de obtener la longitud media y la tendencia media de los segmentos de la TS (potencia media) y el cálculo de mínimos y máximos y su localización.

- Longitud media de los segmentos de la TS: se debe calcular el valor medio del segmento y se fuzzifica. Para calcular el valor medio se utiliza la Ecuación 10.

$$l_{med} = argmax_L \mu_L\left(\frac{|TS|}{|FPLS|}\right) \forall L \in LONG \quad (10)$$

donde la operación “ $|$ ” es la anchura del soporte de *TS*.

El valor obtenido ( $\frac{|TS|}{|FPLS|}$ ) se fuzzificará utilizando el conjunto de etiquetas *LONG* que define la longitud.

- Tendencia media de la TS: para obtener la potencia de la tendencia media se utilizará el Algoritmo 1. Éste defuzzifica la etiqueta que define la potencia de cada tendencia acumulando todos los valores de defuzzificación

---

**Algorithm 1** Cálculo de longitud media de las tendencias
 

---

```

1:  $v_{med} = 0.0$  {acumula la longitud}
2: for  $i = 0$  to  $|FPLS|$  do
3:    $v_{med} = v_{med} + defuzz(type_{i+1})$ 
4: end for
5:  $v_{med} = \frac{v_{med}}{|FPLS|}$  {longitud media}
6:  $type_{med} = argmax_{E_j} \mu_{E_j}(v_{med})$  {selecciona la etiqueta de máxima pertenencia}
    
```

---

en  $v_{med}$  (Línea 3). Finalmente, se vuelve a fuzzificar el valor medio obtenido (Línea 5) utilizando el conjunto original de etiquetas u otro distinto (según se necesite) para la descripción final (Línea 6). Para realizar la defuzzificación hay diferentes propuestas en la bibliografía, algunas opciones interesantes se detallan en [16]. La opción utilizada en los ejemplos de este trabajo ha sido la media de máximos (Mean of Maximum – MoM).

- Mínimos y máximos y su localización: FPLS permite la localización de mínimos y máximos comprobando el tipo de tendencia para dos tendencias consecutivas. Si se verifica la Ecuación 11 o 12 se ha localizado un mínimo o un máximo respectivamente.

$$(type_i = descendente) \wedge (type_{i+1} = ascendente) \quad (11)$$

$$(type_i = ascendente) \wedge (type_{i+1} = descendente) \quad (12)$$

donde  $descenso \in TYPE$  y  $ascenso \in TYPE$ .

La localización del máximo viene indicada por el instante final de  $fpls_{t_i, t_{i+1}}$  o por el inicial de  $fpls_{t_{i+1}, t_{i+2}}$  (es el mismo instante,  $t_{i+1}$ ). Dado que FPLS es una representación aproximada se puede realizar una fuzzificación de  $t_{i+1}$  en base a la localización de dicho instante dentro del soporte del tiempo (Ecuaciones 13 y 14).

$$min_k = \mu_{TIME}(t_{min}) \quad (13)$$

$$max_k = \mu_{TIME}(t_{max}) \quad (14)$$

donde  $t_{min}$  y  $t_{max}$  son los instantes donde se ha detectado el mínimo o el máximo respectivamente.

Una vez detallado la forma de extraer información de la FPLS se expondrá la forma de generar las descripciones lingüísticas a partir de la FPLS. Para ello es necesario el uso de plantillas que ayuden a la generación de las descripciones. Primeramente se definirá una plantilla que utiliza el tipo y la potencia de la tendencia, la longitud de la misma y su localización. Ésta es:

Es una tendencia  $T \in TYPE$  que muestra un  $P \in POWER$  de una longitud  $L \in LONG$  situada en *LOC*.

Utilizando el FPLS de la Tabla I y los conjuntos de etiquetas en las Tablas de la II a la V se obtienen los resultados que se muestran en la Tabla VI. Las etiquetas generadas se destacan en el texto.



TABLE VI  
UN FPLS DE EJEMPLO. FUENTE MORENO-GARCIA ET AL. [5]

$fpls_{t_i, t_{i+1}}$	Descripción lingüística
$fpls_{0,0, 17.0}$	Es una tendencia descendente que muestra un descenso de una longitud corta situada al inicio pasado.
$fpls_{17.0, 49.0}$	Es una tendencia ascendente que muestra un ascenso de una longitud un poco corta situada al centro.
$fpls_{49.0, 91.0}$	Es una tendencia descendente que muestra un descenso de una longitud media situada al centro pasado.
$fpls_{91.0, 94.0}$	Es una tendencia plana que muestra un llano de una longitud muy corta situada al centro pasado.
$fpls_{94.0, 131.0}$	Es una tendencia descendente que muestra un ascenso de una longitud media situada al centro pasado.

A continuación se expone un ejemplo utilizando el mismo FPLS que en el caso anterior que genera una descripción lingüística que detalla la longitud media de los segmentos, la tendencia media de la TS y los mínimos y máximos de la TS. La plantilla utilizada es la siguiente:

La TS tiene una tendencia media *POWER* y sus segmentos son de una longitud *LMEDIA*. En el  $min_k$  se presenta un mínimo y se encuentra un máximo en el  $max_k$ .

El resultado obtenido es el siguiente:

La TS tiene una tendencia media llana y sus segmentos son de una longitud un poco corta. En el instante inicio pasado se presenta un mínimo y se encuentra un máximo en el inicio pasado.

## V. CONCLUSIONES Y TRABAJOS FUTUROS

En este trabajo se ha presentado un nuevo método de generación de descripciones lingüísticas de TS a partir de la información capturada en una FPLS. Se ha mostrado cómo obtener información a partir de FPLS y qué se puede obtener a partir de la misma. También se ha detallado la forma en la que puede ser utilizada para generar descripciones lingüísticas. Se ha demostrado que FPLS contiene suficiente información de la TS para generar descripciones completas y complejas. Además, la forma de obtener dicha información es sencilla y eficiente permitiendo así la generación de descripciones de forma rápida.

Como trabajos futuros se pretende estudiar más detalladamente la información que se puede obtener de una FPLS. También se puede trabajar en la generación de descripciones del proceso de comparación de dos FPLS, por ejemplo, describir la comparación de partes de la serie que interesa comparar (por ejemplo, fases de un movimiento), o bien de partes que tienen un mayor parecido entre ellas. Cada una de estas partes puede corresponder a los valores que toma un sistema durante una fase. Finalmente se debe investigar

en la creación de un marco de trabajo que permita generar las descripciones lingüísticas de una forma totalmente automática.

## REFERENCES

- [1] E. Keogh, S. Chu, D. Hart, and M. Pazzani, "An online algorithm for segmenting time series," Proceedings 2001 IEEE International Conference on Data Mining, pp. 289–296, 2001.
- [2] X. Huang, M. Matijaš, and J. A. K. Suykens, "Hinging Hyperplanes for Time-Series Segmentation," IEEE Transactions on Neural Networks and Learning Systems, vol. 24(8), 2013.
- [3] E. Fuchs and T. Gruber and J. Nitschke, and B. Sick, "Online Segmentation of Time Series Based on Polynomial Least-Squares Approximations," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 32(12), pp. 2232–2245, 2010.
- [4] N. Marín, and D. Sánchez, "On generating linguistic descriptions of time series," Fuzzy Sets and Systems, vol. 285, pp. 6–30, 2016.
- [5] A. Moreno-García, J. Moreno-García, Luis Jimenez-Linares, and Luis Rodríguez-Benítez, "Time series represented by means of fuzzy piecewise linear segments," Journal of Computational and Applied Mathematics, vol. 318, pp. 156–167, 2017.
- [6] A. Laurent, "Generating fuzzy summaries from fuzzy multidimensional databases," in: F. Hoffmann, D.J. Hand, N.M. Adams, D.H. Fisher, G. Guimarães (Eds.), IDA, in: Lecture Notes Computer Sciences, Springer, vol. 2189, pp. 24–33, 2001.
- [7] R. Castillo-Ortega, N. Marín, and D. Sánchez, "A fuzzy approach to the linguistic summarization of time series," Journal of multiple-valued logic and soft computing, vol. 17(2-3), pp. 157–182, 2011.
- [8] R. Castillo-Ortega, N. Marín, and D. Sánchez, "Linguistic query answering on data cubes with time dimension," International Journal of Intelligent Systems, vol. 26(10), pp. 1002–021, 2011.
- [9] A. Ramos-Soto, A. Bugarin, and S. Barro and J. Taboada, "Linguistic descriptions for automatic generation of textual short-term weather forecasts on real prediction data," IEEE Transactions on Fuzzy Systems, vol. 23(1), pp. 44–57, 2015.
- [10] J. Moreno-García, L. Rodríguez-Benítez, J. Giralt, and E. del Castillo, "The generation of qualitative descriptions of multivariate time series using fuzzy logic," Applied Soft Computing, vol. 23, pp. 546–555, 2014.
- [11] J. Moreno-García, J. Abián-Vicén, L. Jimenez-Linares, and L. Rodríguez-Benítez, "Description of multivariate time series by means of trends characterization in the fuzzy domain," Fuzzy Sets and Systems, vol. 285, pp. 118–139, 2016.
- [12] J. Kacprzyk, and A. Wilbik, "Linguistic summarization of time series using a fuzzy quantifier driven aggregation," Fuzzy Sets and Systems, vol. 159, pp. 1485–1499, 2008.
- [13] D. Anderson, R.H. Luke III, J.M. Keller, M. Skubic, M. Rantz, and M. Aud, "Linguistic summarization of video for fall detection using voxel person and fuzzy logic", Computer Vision Image Understanding, vol. 113(1), pp. 80–89, 2009.
- [14] G. Triviño, and M. Sugeno, "Towards linguistic descriptions of phenomena", International Journal of Approximate Reasoning, vol. 54(1), pp. 22–34, 2013.
- [15] D. Sanchez-Valdes, and G. Triviño, "Computational Perceptions of uninterpretable data. A case study on the linguistic modeling of human gait as a quasi-periodic phenomenon", Fuzzy Sets and Systems, vol. 253, pp. 101–121, 2014.
- [16] W. V. Leekwijck, E. E. Kerre., "Defuzzification: criteria and classification", Fuzzy Sets and Systems, vol. 108(2), pp. 159–178, 1999.



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

OSCAR CORDÓN

RAFAEL MARTÍ

**Secretaría Técnica:**

DANIEL MOLINA Y MARÍA ISABEL GARCÍA





**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 1: APLICACIONES DE  
LAS METAHEURÍSTICAS







# Evolving Geographically-embedded Complex Networks using the CRO-SL Algorithm

1<sup>st</sup> Sancho Salcedo-Sanz

Dept. of Signal Processing and Communications  
Universidad de Alcalá  
Alcalá de Henares, Spain  
sancho.salcedo@uah.es

2<sup>nd</sup> Lucas Cuadra

Dept. of Signal Processing and Communications  
Universidad de Alcalá  
Alcalá de Henares, Spain  
lucas.cuadra@uah.es

**Abstract**—This paper deals with the problem of evolving geographically-embedded randomly generated complex networks aiming at fulfilling the scale-free property: the fraction of nodes in the network having degree  $k$  ( $k_i =$  number of links in node  $n_i$ ) follows a power law probability distribution  $P(k) \sim k^{-\gamma}$ . Intuitively, this means that most nodes have only a few connections and only a few nodes (“hubs”) have a high number of links (or connections). The scale-free property is well-known in very large complex networks (with a huge number of nodes and links) but it has received much less attention for small geographically-embedded networks, in which the study of networks’ properties is much more difficult. Regarding this, we explore the feasibility of generating geographically-embedded complex networks even in the case of small networks (those with only hundred of nodes) by means of considering a simple model for network generation based on distances among nodes. We state the problem as an optimization task, in which each node of the network has a link radius assigned to conform its links to other nodes in the network. The idea is to evolve these link radius for all the nodes in the network, aiming at finally fulfilling the scale-free property, when possible. Our machine learning approach for network evolution is based on the recently proposed meta-heuristic called Coral Reefs Optimization algorithm with Substrate Layer (CRO-SL). Our experimental work shows that the proposed model is able to generate geographically (or spatially) embedded networks with the scale-free property. Specifically, we test the performance of the CRO-SL approach in two different, randomly generated, geographically-embedded networks with 200 and 400 nodes, respectively.

**Index Terms**—Geographically-embedded complex networks; Scale-free networks; Meta-heuristics; CRO-SL.

## I. INTRODUCTION

What do systems as different as power grids and ecosystems have in common? Both can be described in terms of graphs: a node represents an entity (generator/load in a power grid, or a species in an ecosystem) that is linked with others (by electrical cables in the power grid or trophic relationships in an ecosystem). These and other dissimilar systems are called complex systems because it is extremely difficult to deduce their emerging collective behavior from only the components of the system [1]. Their topological and dynamical features can be studied using the Complex Network (CN) Science [1]. The interested reader is referred to [1], which clearly explains of

This work has been partially supported by the project TIN2017-85887-C2-2-P of the Spanish Ministerial Commission of Science and Technology (MICYT).

CN concepts with a profuse variety of examples in both natural (metabolic networks, gene interactions, food webs, etc.) and artificial systems (the Internet, transport networks, or power grids). In particular, the feasibility of using CN concepts in power grids have been recently discussed in [2] and [3] in combination with evolutionary algorithms in smart grids. More profound technical details about CN can be found in [4], [5], [6], [7] and the references there in.

Most recent studies reveal that many CNs –such as some power grids or the Internet– have a heterogeneous topology [1] as the one represented in Fig. 1 (a). Note that most nodes have only a few connections and only a few nodes (“hubs”) have a high number of links. This is why the network is said to have “no scale”, so it is called “scale-free” [1]. As shown in Fig. 1 (b), the fraction of nodes having degree  $k$  ( $k_i =$  number of links in node  $i$ ) exhibits a power law distribution  $P(k) \sim k^{-\gamma}$ .

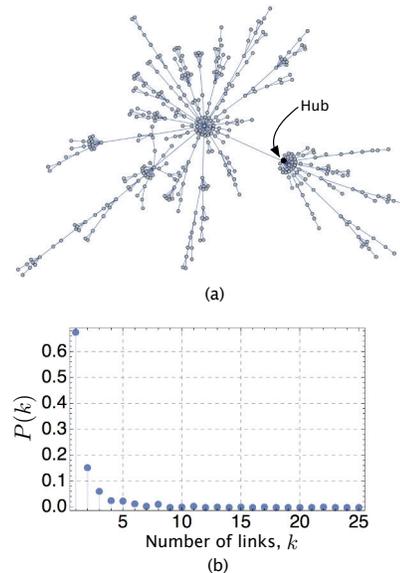


Fig. 1. (a) Example of a scale-free complex network with 400 nodes. (b) Node degree probability density function of a network similar to that represented in (a).

In many of these CNs (for instance, citation networks) the position of nodes in the physical space plays no role at all [8]. However there are other CNs (such as transportation, infrastructure and wireless communication networks) in which nodes and links are embedded in space. In this particular kind of CNs, called “spatial networks” (spatially-embedded or geographically-embedded networks), nodes are located in a space associated to a metric, usually the Euclidean distance [8], [9], [10]. The interested reader is referred to [8] for further details about spatial networks, which can be classified into two categories [8]. The first one, called planar networks, are those that can be drawn in the plane in such a way that their links do not intersect. The second one involves spatial non-planar networks (for instance airline networks, cargo ship networks, or power grids) where links (which can intersect in the plane) have a cost related to their length. Although the scale-free property is well-known in very large, non-spatial complex networks (with a huge number of nodes), however it is not the case in small geographically-embedded networks. This is because, in spatial networks, when geometric constraints are very strong or when the cost associated to the addition of new links is large (water and gas distribution networks, power grids, or communication networks), the appearance of hubs and the scale-free feature become more difficult [8].

In this paper we show that any randomly generated network can be constructed to very approximately follow a scale-free distribution. This result has only been previously proven for geographically-embedded network in a regular lattice [10]. To show this result, we first propose a very simple model for randomly constructing geographically-embedded networks, which consists in assigning a *link radius* to each new node of the network. The proposed model for network construction establishes that each link radius may be different for each node, and it is fully related to the network construction: when a node is randomly generated, it is linked with all other existing nodes in the network which are at a distance smaller than its link radius. In order to show that the network follows a scale-free distribution, we evolve it, i.e. we use an evolutionary-based algorithm in order to assign link radius to all the nodes in the network. The objective is that, eventually, the network follows (approximately) a scale-free distribution. We state this problem as an optimization task, with discrete-based encoding, in which a meta-heuristic search must be applied (since brute-force schemes are discarded due to excessive computational cost). Specifically, we evaluate the performance of the Coral Reefs Optimization algorithm with Substrate Layer (CRO-SL) in this problem of complex networks evolution. We will show that the CRO-SL is able to lead to randomly generated geographically-embedded complex networks fulfilling the scale-free property, and we show it in two cases with randomly generated network of 200 and 400 nodes.

The remainder of the paper has been structured in the following way: next section presents the model we consider to construct geographically-embedded complex networks with randomly-distributed nodes. Section III describes the evolution of the network as an optimization task, defining the encoding,

search space and objective function of the problem. Section IV shows the main characteristics of the CRO-SL considered in this paper. Section V describes the experimental part of the paper, with computational results over two randomly generated networks with 200 and 400 nodes. Section VI gives some final conclusions and remarks to close the paper.

## II. GROWING GEOGRAPHICALLY-EMBEDDED COMPLEX NETWORKS OVER RANDOM-DISTRIBUTED NODES

Let us consider a model for growing geographically-embedded complex networks using randomly-distributed nodes. The idea is to grow the network as the random nodes are being generated. Note that since we consider a random location for the new generated nodes, the network is completely constructed from scratch. We can consider many different random ways of generating the network nodes, but in any case, a constraint of maximum distance from a neighbor to others node must be fulfilled. In order to do this, we consider an extremely simple model for nodes generation, in which the new appearing node must be located at a minimum distance from another neighbor node,  $R_a$  (attachment radius), to be attached to the network. Otherwise it will be discarded. Note that this radius may be characteristic of the node  $i$  currently being generated so that, in this case, we will denote it as  $R_a^i$ . However, in the general case, all the nodes in the network will be generated with the same  $R_a$ , this simulation parameter being thus equal for all nodes. As previously mentioned, the network will be grown while random nodes are being generated. Aiming at doing this, we propose a simple mechanism for links generation for a new node  $i$ : let  $R_l^i$  be the *link radius* associated with the recently generated node  $i$ , and let  $\mathbf{L}$  be the link matrix, in which  $L_{ij}$  stands for a binary variable describing whether or not there is a link between node  $i$  and an alternative node  $j$ . Then, each time a node  $i$  is generated, it establishes links to other nodes already attached, in the following way:

$$L_{ij} = \begin{cases} 1, & \text{if } d(i, j) < R_l^i \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

where  $d(i, j)$  stands for the Euclidean distance (not the geodesic one used in non-spatial networks [8]) between node  $i$  and any other existing node ( $j$ ). It is important to note that the number of links established when the node  $i$  is finally generated attached, not discarded) will only depend on  $R_l^i$ . Moreover, if we want to ensure that all the nodes are connected with at least one other node in the network, then  $R_l^i \geq R_a$ .

To illustrate this, let us consider the examples shown in Fig. 2. The first one, in Fig. 2 (a), shows a random network generated with parameters  $R_a = 10$  and  $R_l^i = 10$  (in this case the same value of  $R_l^i$  for all the nodes generated in the network). Note that, since  $R_l^i = R_a$ , each node will be attached to a very reduced number of other existing nodes in the network. If we keep  $R_a = 10$  in the node generation, but  $R_l^i$  takes values in  $[10, 15, 20, 30]$ , depending on the node



generated, then we obtain the network represented in Fig. 2 (b).

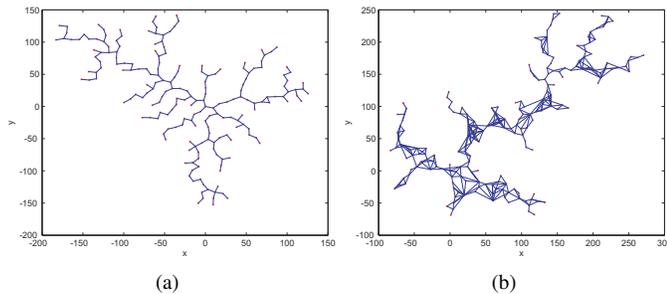


Fig. 2. Example of geographically embedded complex networks generated with the proposed simple model considering  $R_a$  and  $R_i^i$ ; (a) Example of complex network with  $R_a = 10$  and  $R_i^i = 10$ ; (b) Example of complex network with  $R_a = 10$  and  $R_i^i \in [10, 15, 20, 30]$ .

### III. QUASI-SCALE FREE GEOGRAPHICALLY-EMBEDDED NETWORKS WITH RANDOM NODES

Let us consider a random-based geographically-embedded network with  $N$  nodes (“network order” =  $N$ ). This means that, after the node generation process, there will be  $N$  nodes in the network. Recall that the network is being constructed dynamically, so each time a node  $i$  is generated and fulfils the  $R_a$  condition, then matrix  $\mathbf{L}$  is modified to include the new node links. Let us consider a given  $R_a$  for the complete network construction and specific  $R_i^i$  radius for each node, and  $R_a \geq R_i^i$ . Let  $\mathbf{r} = [R_1^1, \dots, R_N^N]$  the link radius associated with the  $N$  nodes finally forming the network. The idea is to obtain a vector  $\mathbf{r}^*$  which makes the network have a scale-free behavior, i.e., such that it minimizes the following objective (fitness) function:

$$f(\mathbf{r}) = \sum_{k=2}^N (p_k(\mathbf{r}) - k^{-\gamma}) \quad (2)$$

where  $p_k$  stands for the degree distribution of the random network obtained with a vector  $\mathbf{r}$ . Note that we aim to find out whether or not there is a  $\mathbf{r}^*$  leading to a power law distribution with a given  $\gamma$ .

This problem is therefore stated as an integer optimization problem, in which the final network degree distribution will completely depend on  $\mathbf{r}$ . The problem is discrete, highly non-linear, and the search space size is huge when the network order  $N$  grows, which discards exact solutions via *brute force* algorithms. In these kind of problems meta-heuristics approaches such as Evolutionary Computation-based algorithms are able to obtain very good solutions with a moderate computational complexity. We therefore propose to apply a kind of Evolutionary Algorithm, the aforementioned CRO-SL approach, to solve this optimization problem associated with scale-free random-based networks. The question arising

here is whether or not the proposed model for complex network construction over geographically embedded random nodes can generate scale-free networks. Note that in this case the random situation of nodes makes impossible to obtain an exact solution such as the one shown for square lattices in [10]. The approach, therefore, should be stochastic due to the nature of the considered networks, and approximate solutions could arise.

### IV. OPTIMIZATION METHOD: THE CRO-SL ALGORITHM

The Coral Reef Optimization algorithm (CRO) [12] (further described in [13]), is an evolutionary-type algorithm based on the behavior of the processes occurring in a coral reef. For an illustrative description of the CRO algorithm, the interested reader is referred to [12], [13]. Additionally, in [14], a new version of the CRO algorithm with Substrate Layer, CRO-SL, has been presented. In the CRO-SL approach, several *substrate layers* (specific parts of the population) have been introduced. In this algorithm, each substrate layer may represent different processes (different models, operators, parameters, constraints, repairing functions, etc.). Specifically, in [15] a version of the CRO-SL algorithm has been recently proposed, in which each substrate layer represents a different search procedure, leading to a co-evolution competitive algorithm. This version of the CRO-SL has been successfully tested in different applications and problems such as micro-grid design [16], vibration cancellation in buildings, both with passive models [17], and active models [18], or in the evaluation of novel non-linear search procedures [19]. This is also the CRO-SL algorithm used in this paper for complex network evolution.

Regarding the algorithm’s encoding for the optimization problem at hand, we consider integer vectors as solutions,  $\mathbf{x} \in \mathbb{N}$ . Note that using this encoding the length of each individual is equal to  $N$ . This encoding provides a compact version of the algorithm, and allows using some different searching procedures such as Harmony Search or Differential Evolution. The main problem with a direct encoding of  $N$  integer values in the CRO-SL algorithm is that, as  $N$  grows, the searching capabilities of the algorithm can be affected, since the search space is huge. It is possible to manage shorter encodings by using a compressed version of the encoding, in such a way that each element of the encoding represents  $\beta$  actual values, such as we proposed in [20]. Fig. 3 shows an example of this compressed encoding, which reduces the current encoding length  $l$  to  $l' = \frac{l}{\beta}$ . Of course, the resolution of the search space is smaller than in the original encoding when the compressed encoding is applied, but on the other hand, it is expected that the CRO-SL algorithm searches for better solutions in this smaller search space.

The considered substrates for solving the stated problem are detailed below. Note that there are general purpose substrates, such as Differential Evolution or Harmony Search-based, and other specific substrates with crossovers and mutations adapted to the chosen encoding. Five different substrates will be described and evaluated later in the experimental section.

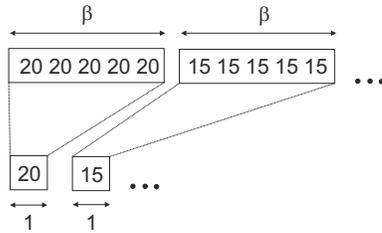


Fig. 3. Compressed encoding example ( $\beta = 5$ ), useful in the evolution of complex networks.

- Differential Evolution-based operator (DE):** This operator is based on the evolutionary algorithm with that name [22], a method with powerful global search capabilities. DE introduces a differential mechanism for exploring the search space. Hence, new larvae are generated by perturbing the population members using vector differences of individuals. Perturbations are introduced by applying the rule  $x'_i = x_i^1 + F(x_i^2 - x_i^3)$  for each encoded parameter on a random basis, where  $x'$  corresponds to the output larva,  $x^t$  are the considered parents (chosen uniformly among the population), and  $F$  determines the evolution factor weighting the perturbation amplitude.
- Harmony Search-based operator (HS):** Harmony Search [23] is a population based MH that mimics the improvisation of a music orchestra while its composing a melody. This method integrates concepts such as harmony aesthetics or note pitch as an analogy for the optimization process, resulting in a good exploratory algorithm. HS controls how new larvae are generated in one of the following ways: i) with a probability HMCR  $\in [0, 1]$  (Harmony Memory Considering Rate), the value of a component of the new larva is drawn uniformly from the same values of the component in the other corals. ii) with a probability PAR  $\in [0, 1]$  (Pitch Adjusting Rate), subtle adjustments are applied to the values of the current larva, replaced with any of its neighboring values (upper or lower, with equal probability).
- Two points crossover (2Px):** 2PX [21] is considered one of the standard recombination operators in evolutionary algorithms. In the standard version of the operator, two parents from the reef population are provided as input. A recombination operation from two larvae is carried out by randomly choosing two crossover points, interchanging then each part of the corals between those points.
- Multi-points crossover (MPx):** Similar to the 2PX, but in this case the recombination between the parents is carried out considering a high number of crossover points ( $M$ ), and a binary template which indicates whether each part of one parent is interchanged with the corresponding of the other parent.
- Standard integer Mutation (SM):** This operator consists of a standard mutation in integer-based encodings. It

consists of mutating an element of a coral with another valid value (different from the previous one). Note that the SM operator links a given coral (possible solution) to a neighborhood of solutions which can be reached by means of a single change in an element of the coral.

## V. EXPERIMENTS AND RESULTS

In this section we show different computational results obtained with the CRO-SL in the evolution of two different random networks with 200 and 400 nodes, respectively. The resulting randomly generated nodes have been represented in Fig. 4 without the corresponding links which form the network, for the sake of clarity. In both cases, a common  $R_a = 10$  value has been considered, whereas the link radius to be assigned by the CRO-SL has been forced to fulfill the property  $10 \leq R_l^i \leq 100$ . Table I shows the corresponding values for the CRO-SL parameters considered in the experiments carried out.

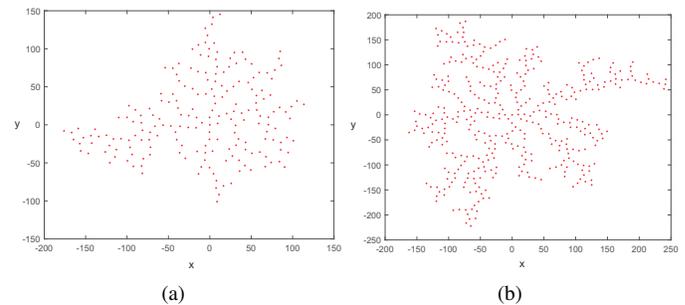


Fig. 4. Randomly-generated nodes for the  $N = 200$  and  $N = 400$  networks (represented without links, and with  $R_a = 10$ ); (a)  $N = 200$ ; (b)  $N = 400$ .

TABLE I  
PARAMETERS OF THE CRO-SL USED IN THE EVOLUTION OF THE NETWORKS CONSIDERED. SEE [12], [13] FOR FURTHER DETAILS ABOUT THE PARAMETERS.

CRO-SL	Parameters
Initialization	Reef size = $50 \times 40$ , $\rho_0 = 0.9$
External sexual reproduction	$F_b = 0.80$
Substrates	$\mathcal{T} = 5$ substrates: HS, DE, 2Px, MPx, SM
Internal sexual reproduction	$1 - F_b = 0.20$
Larvae setting	$\kappa = 3$
Asexual reproduction	$F_d = 0.05$
Depredation	$F_d = 0.15$ , $P_d = 0.05$
Stop criterion	$k_{max} = 500$ iterations

First, we have tackled the evolution of the  $N = 200$  network, from scratch by using the CRO-SL algorithm. A compressed encoding with  $\beta = 5$  has been considered so that the corals length is in this case  $l' = \frac{200}{5} = 40$ . Fig. 5 shows the results obtained by the CRO-SL in the evolution of this network. Fig. 5 (a) shows the network obtained after the optimization process, which has obtained an excellent



agreement of the network distribution node degree with a power law distribution  $k^{-1.55}$  (Fig. 5 (b)). Note that, in this case, we have explored 12 values of the node degree  $k$  in the network, ranging from 2 to 12, while the rest bring in upper values of  $k$ . The best solution  $\mathbf{r}^*$  found by the CRO-SL algorithm has been represented in Fig. 5 (c), note the runs of  $\beta = 5$  equal values in the solution. Fig. 5 (d) shows the fitness evolution of the best coral in the reef. As can be seen, the CRO-SL is able to converge almost up to optimality in just 500 generations, showing a fast and robust behaviour in this problem.

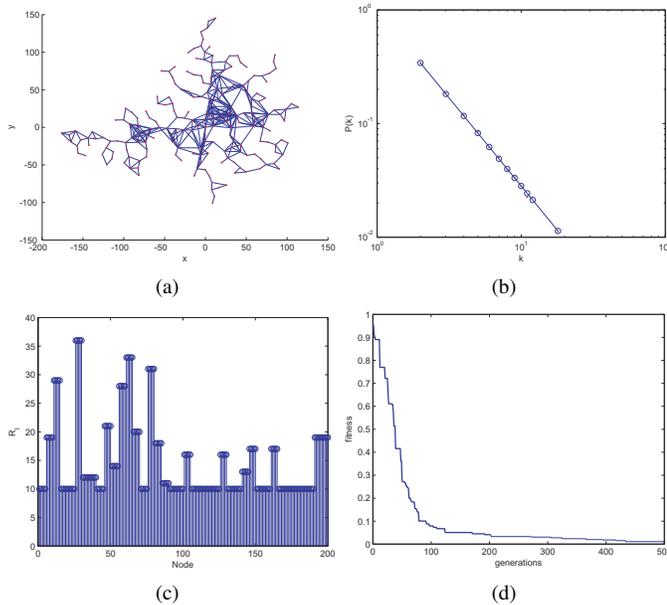


Fig. 5. Example of geographically-embedded complex network with  $N = 200$  nodes, evolved with the CRO-SL algorithm; (a) Resulting spatial network obtained; (b) Node degree distribution for the network represented in (a): blue circles stand for the power law distribution  $k^{-1.55}$ , and red points for the actual degree distribution of the obtained network; (c) Best solution obtained with the CRO-SL; (d) CRO-SL fitness evolution.

Fig. 6 shows the results obtained by the CRO-SL in the evolution of the second network considered, with a network order of  $N = 400$  nodes. In this case, we have considered a compressed encoding with  $\beta = 10$ , which leads to a  $l' = \frac{400}{10} = 40$ , similar to the  $N = 200$  case. We have found that this compressed encoding provides the best results. Fig. 6 (a) shows the resulting network generated by the CRO-SL algorithm, which is constructed to very approximately follow a power law distribution  $k^{-1.59}$ . In this case we have explored 15 values of the degree  $k$ , from 2 to 15 and a rest in upper values of  $k$ . The best solution  $\mathbf{r}^*$  found by the CRO-SL algorithm has been displayed in Fig. 6 (c). Note the runs of  $\beta = 10$  equal values in the solution. Fig. 7 shows the network evolution process in 6 steps for the best solution found by the CRO-SL. In this figure it is possible to see the process of network construction as the nodes are being attached. It is important to

take into account that the spatial network construction depends on the position of the randomly generated nodes (we have considered geographically-embedded networks), controlled by  $R_a$  and also in the values of  $R_i^i$ , which are evolved by the CRO-SL algorithm.

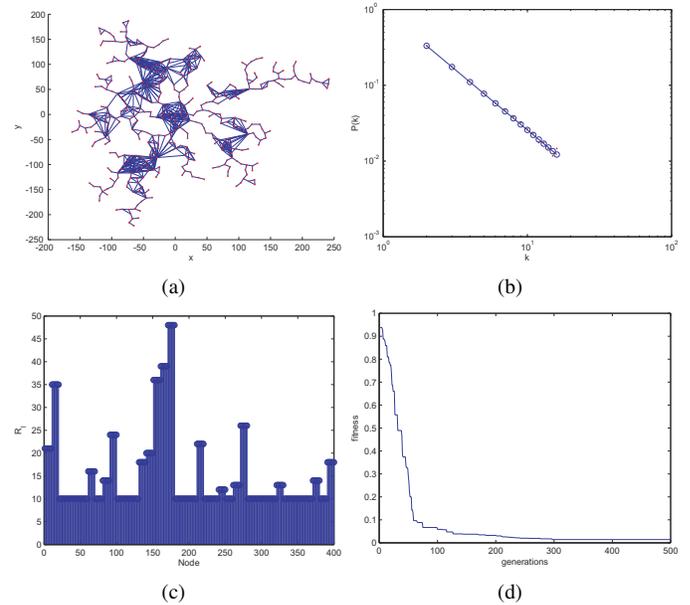


Fig. 6. Example of geographically-embedded complex network with  $N = 400$  nodes, evolved with the CRO-SL algorithm; (a) Resulting geographically-embedded network ; (b) Node degree distribution for the network represented in (a): blue circles stand for the power law distribution  $k^{-1.59}$ , and red points for the actual degree distribution of the obtained network; (c) Best solution obtained with the CRO-SL; (d) CRO-SL fitness evolution.

As can be seen in the results obtained, it is possible to obtain quasi-scale-free geographically-embedded random networks, considering a very simple model of distances between nodes. It is necessary to solve an optimization problem, which is hard, since it must optimize the link radius of all the randomly generated nodes which form the network. We have shown how the CRO-SL algorithm is able to successfully solve this task, finding near optimal solutions to the optimization problem.

## VI. SUMMARY AND CONCLUSIONS

In this paper we have shown that random geographically-embedded networks can be constructed, in such a way that they fulfil the scale-free property, i.e. the fraction of nodes in the network having degree  $k$  ( $k_i =$  number of links in node  $n_i$ ) follows a power law probability distribution  $P(k) \sim k^{-\gamma}$ . Up until now, the scale-free property in geographically-embedded network has only been studied for regular networks in a mesh. We have considered completely randomly generated nodes for the networks, and we have established the on-line construction of the network, following a very simple model which only depends on the distances between new generated nodes and existing nodes in the network ( $R_i^i$ ). We

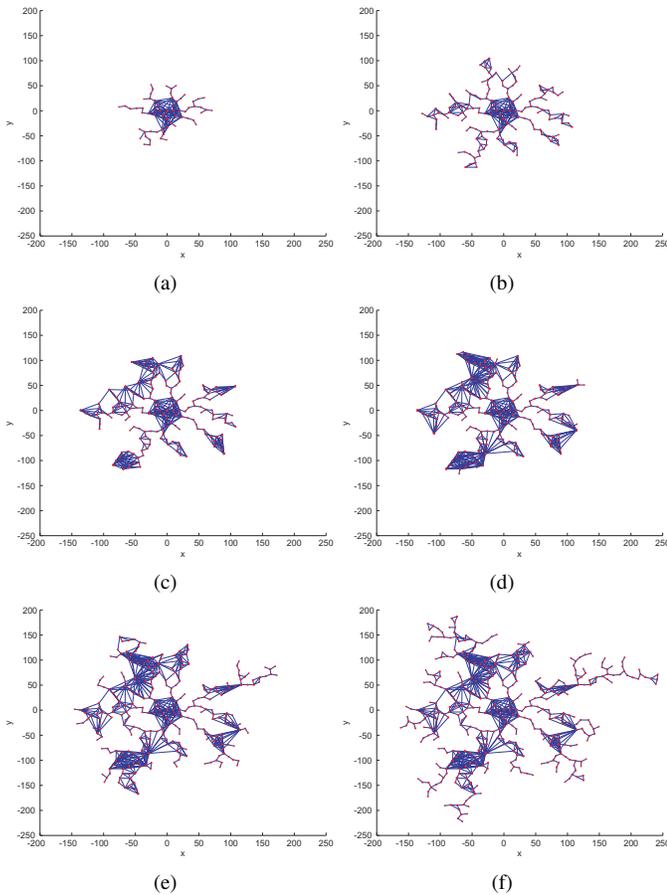


Fig. 7. Network evolution process in 6 steps for the  $N = 400$  case (best solution obtained with the CRO-SL algorithm).

propose then the evolution of the network with the objective of fulfilling the scale-free property: we have described this problem as an optimization task, consisting on assigning a given link radius  $R_l^i$  to each node of the network, as soon as it is randomly generated. The optimal assignment of these link radius leads to an evolution of the network to be quasi-scale-free when it is completely constructed. We have applied the modern meta-heuristic Coral Reefs Optimization with Substrate Layers (CRO-SL), which is able to combine different searching procedures within a single-population algorithm. A discussion on the optimal problem's encoding with different lengths using a compression procedure is also carried out. We have successfully tested the CRO-SL in two randomly generated networks of 200 and 400 nodes, where we have shown that the CRO-SL is able to obtain quasi-scale free geographically-embedded networks when it is applied.

## REFERENCES

- [1] A.L. Barabási and M. and Pósfai, Network Science. Cambridge University Press, Cambridge, UK, 2016.
- [2] L. Cuadra, M. del Pino, J. C. Nieto-Borge, and S. Salcedo-Sanz, "A critical review of robustness in power grids using complex networks concepts," *Energies*, vol. 8, no. 9, pp. 9211-9265, 2015.
- [3] L. Cuadra, M. del Pino, J. C. Nieto-Borge, and S. Salcedo-Sanz, "Optimizing the Structure of Distribution Smart Grids with Renewable Generation against Abnormal Conditions: A Complex Networks Approach with Evolutionary Algorithms," *Energies*, vol. 10, no. 8, pp. 1097, 2017.
- [4] S. H. Strogatz, "Exploring complex networks," *Nature*, vol. 410, no. 6825, pp. 268, 2001.
- [5] R. Albert and A. L. Barabási, "Statistical mechanics of complex networks," *Reviews of modern physics*, vol. 74, no. 1, pp. 47, 2002.
- [6] M. E. Newman, "The structure and function of complex networks," *SIAM review*, vol. 45, no. 2, pp. 167-256, 2003.
- [7] S. V. Buldyrev, R. Parshani, G. Paul, H. E. Stanley, and S. Havlin, "Catastrophic cascade of failures in interdependent networks," *Nature*, vol. 45, no. 7291, pp. 1025, 2010.
- [8] M. Barthélemy, "Spatial networks," *Physics Reports*, vol. 499, no. 1-3, pp. 1-101, 2011.
- [9] M. Barthélemy, *Morphogenesis of Spatial Network*, Springer, 2017.
- [10] K. Kosmidis, S. Havlin and A. Bunde, "Structural properties of spatially embedded networks," *Europhysics Letters*, vol. 82, no. 4, pp. 1-5, 2008.
- [11] A. L. Barabási and R. Albert, "Emergence of scaling in random networks" *Science*, vol. 286, pp. 509-512, 1999.
- [12] S. Salcedo-Sanz, J. del Ser, I. Landa-Torres, S. Gil-López and A. Portilla-Figuera, "The Coral Reefs Optimization algorithm: a novel metaheuristic for efficiently solving optimization problems," *The Scientific World Journal*, 2014.
- [13] S. Salcedo-Sanz, "A review on the coral reefs optimization algorithm: new development lines and current applications," *Progress in Artificial Intelligence*, vol. 6, pp. 1-15, 2017.
- [14] S. Salcedo-Sanz, J. Muñoz-Bulnes and M. Vermeij, "New coral reefs-based approaches for the model type selection problem: a novel method to predict a nation's future energy demand," *International Journal of Bio-Inspired Computation*, vol. 10, no. 3, pp. 145-158, 2017.
- [15] S. Salcedo-Sanz, C. Camacho-Gómez, D. Molina and F. Herrera, "A Coral Reefs Optimization algorithm with substrate layers and local search for large scale global optimization," *In Proc. of the IEEE World Congress on Computational Intelligence*, Vancouver, Canada, July, 2016.
- [16] S. Salcedo-Sanz, C. Camacho-Gómez, R. Mallol-Poyato, S. Jiménez-Fernández and J. del Ser, "A novel Coral Reefs Optimization algorithm with substrate layers for optimal battery scheduling optimization in micro-grids," *Soft Computing*, vol. 20, pp. 4287-4300, 2016.
- [17] S. Salcedo-Sanz, C. Camacho-Gómez, A. Magdaleno, E. Pereira and A. Lorenzana, "Structures vibration control via tuned mass dampers using a co-evolution coral reefs optimization algorithm," *Journal of Sound and Vibration*, vol. 393, pp. 62-75, 2017.
- [18] C. Camacho-Gómez, X. Wang, I. Díaz, E. Pereira and S. Salcedo-Sanz, "Active vibration control design using the Coral Reefs Optimization with Substrate Layer algorithm," *Computers & Structures*, in press, 2017.
- [19] S. Salcedo-Sanz, "Modern meta-heuristics based on nonlinear physics processes: A review of models and design procedures," *Physics Reports*, vol. 655, 1-70, 2016.
- [20] S. Salcedo-Sanz, A. Gallardo-Antolín, J. M. Leiva-Murillo and C. Bousoño-Calzón, "Off-line speaker segmentation using genetic algorithms and mutual information," *IEEE Transactions on Evolutionary Computation*, vol. 10, no. 2, pp. 175-186, 2006.
- [21] A. E. Eiben and J. E. Smith. Introduction to evolutionary computing. Springer-Verlag, Natural Computing Series 1st edition, 2003.
- [22] R. Storn and K. Price, "Differential Evolution - A simple and efficient heuristic for global optimization over continuous spaces," *Journal of Global Optimization* vol. 11, pp. 341-359, 1997.
- [23] Z. W. Geem, J. H. Kim and G. V. Loganathan, "A new heuristic optimization algorithm: Harmony Search," *Simulation*, vol. 76, no. 2, pp. 60-68, 2001.



# Metaheurísticas para calibración de modelos basados en agentes en dinámicas de adopción premium

Ignacio Moya\*, Manuel Chica\*, William Rand†, Oscar Cordón\*

\*Instituto Andaluz Interuniversitario DaSCI (Data Science and Computational Intelligence), Universidad de Granada, España

† Poole College of Management, North Carolina State University, NC, United States

Emails: imoya@ugr.es, manuelchica@ugr.es, wmrans@ncsu.edu, ocordon@decsai.ugr.es

**Resumen**—Las aplicaciones *freemium* están creando nuevos escenarios de marketing, incentivando la adopción de servicios mediante la interacción entre usuarios. Para entender las dinámicas de estas aplicaciones son útiles los modelos basados en agentes, pero deben calibrarse con datos reales para poder ajustar su comportamiento a la realidad. Las metaheurísticas son métodos de optimización frecuentemente usados para calibración de modelos, dado que pueden ajustar los parámetros del modelo. En este artículo comparamos distintas metaheurísticas para calibrar un modelo basado en agentes que replica las dinámicas de adopción de contenido *premium* usando el modelo de Bass. Aplicamos estas metaheurísticas a cuatro datasets y llevamos a cabo un análisis de sensibilidad sobre los parámetros de las soluciones encontradas por los algoritmos. Nuestros experimentos muestran que CMA-ES encuentra mejores soluciones que los demás algoritmos en los distintos datasets de adopción *premium*. Nuestro análisis de sensibilidad muestra un amplio rango de valores para los coeficientes de imitación e innovación del modelo de Bass.

**Index Terms**—calibración de modelos, metaheurísticas, modelo basado en agentes, modelo de negocio *freemium*

## I. INTRODUCCIÓN

El modelo de negocio *freemium* combina la oferta de un producto o servicio sin coste con contenido *premium* que el usuario puede adquirir de manera opcional [1]. Este modelo se está extendiendo en aplicaciones *online* [2], donde están creando nuevos escenarios de marketing dado que este contexto propicia la adopción de productos a través de la interacción entre usuarios [3]. Con estos escenarios también surgen distintos problemas al planear campañas de marketing: qué individuos seleccionar para conseguir una campaña de marketing viral, cómo lidiar con *influencers*, o cómo incentivar a los usuarios a atraer a otros mandando invitaciones a través de sus redes [4]–[7]. Entender estos y otros efectos sociales detrás de las compras de contenido *premium* puede ser más fácil usando un modelo basado en agentes (ABM), puesto que permiten probar recompensas, incentivos, y políticas de *targeting* que incrementen el número de usuarios *premium*.

Un ejemplo es el ABM desarrollado para *Creature Party* [8]. Esta aplicación es un juego social multiplataforma para niños donde el usuario interactúa *online* con otros usuarios, que pueden ser *premium* o básicos. Un usuario básico tiene acceso total al juego pero un usuario *premium* recibe beneficios adicionales como una cantidad semanal de monedas del juego,

la habilidad de adoptar mascotas virtuales, acceso a todos los avatares, y contenido reservado para usuarios *premium* como grupos y aventuras. La metodología ABM [9], [10] utiliza una población de entidades autónomas llamadas agentes que se comportan de acuerdo a reglas simples e interactúan unos con otros. Agregar estas reglas con la interacción entre los agentes nos permite representar dinámicas complejas y emergentes, así como definir escenarios *what-if* y predecir escenarios hipotéticos [11]. Este enfoque encaja con los patrones de crecimiento del mercado que resultan de la interacción de muchos usuarios, que son más complejos que cualquier adopción individual [12]. Gracias a sus aplicaciones exitosas, se ha incrementado el número de trabajos que emplean ABMs, particularmente para analizar la adopción de nuevos productos, políticas de adopción, y estrategias de *targeting* [13], [14].

Concretamente el ABM para *Creature Party* predice el número de usuarios básicos que adquieren contenido *premium* simulando periodos de tiempo específicos y monitorizando el comportamiento de los agentes. Este ABM utiliza información real de la red de usuarios para generar una red artificial [15] con una estructura similar en la que replicar el proceso social de adopción mediante el modelo de Bass [16]. También simula el comportamiento de usuarios siguiendo diferentes patrones estacionales, lo que es muy relevante para las aplicaciones que muestran diferente actividad entre semana que durante fines de semana.

En general, para usar un ABM es necesario validar su comportamiento calibrando sus parámetros. Llevamos a cabo este procedimiento utilizando *data-driven automated calibration*, que consiste en modificar los parámetros del modelo de manera automática y así ajustar su salida a los datos reales. Este proceso es muy importante durante la validación del modelo [12], [17], [18]. Implementamos nuestro proceso de calibración empleando metaheurísticas [19] como algoritmo de búsqueda de la mejor configuración de parámetros del modelo. En este artículo presentamos una comparación de las siguientes metaheurísticas: *hill climbing* [19], algoritmos genéticos [20], *differential evolution* [21], *PSO* [22], y *CMA-ES* [23]. Elegimos estas metaheurísticas de modo que el grupo de métodos sea heterogéneo en cuanto a su complejidad, permitiendo apreciar la ganancia de rendimiento que consiguen métodos más avanzados. El rendimiento de las

metaheurísticas presentadas se basará en lo bien que el modelo calibrado replique los datos reales de *Creature Party*, que se presentan como la evolución de usuarios *premium* a lo largo del tiempo. Estos datos se presentan en distintos periodos de tiempo componiendo los distintos datasets que utilizaremos para validar las metaheurísticas para el problema. Una vez calibrado el modelo para *Creature Party* desarrollamos un análisis de sensibilidad sobre las soluciones generadas enfocándonos en los coeficientes de adopción del modelo de Bass y los parámetros de estacionalidad del modelo, utilizando técnicas de visualización de datos (*scatter plots*) para los valores obtenidos.

En la Sección II describiremos el ABM de adopción de contenido *premium* de *Creature Party*. La Sección III presenta las distintas metaheurísticas empleadas en el proceso de calibración. Mostramos la experimentación y el análisis de sensibilidad en la Sección IV. Por último, remarcamos nuestras conclusiones en la Sección V.

## II. DESCRIPCIÓN DEL MODELO

La Sección II-A presenta la estructura general del modelo. En la Sección II-B se describen los mecanismos y el comportamiento de los agentes, incluyendo sus interacciones sociales en la aplicación. Finalmente presentamos el proceso de adopción seguido por el modelo en la Sección II-C.

### A. Estructura general

El modelo simula la evolución del número de usuarios *premium* durante un periodo de tiempo determinado usando un *time step* diario. De este modo la salida del modelo consiste en los nuevos usuarios *premium* para cada paso de la simulación, que es el indicador principal de este tipo de mercados [24]. Observando la evolución de adopciones *premium* diarias podemos medir como de bien se ajusta el modelo a los datos históricos de las distintas instancias. El modelo ABM para *Creature Party* modela los usuarios existentes como agentes con un factor de escala de 2:1, por lo que 20000 agentes representan los 40000 usuarios activos de la aplicación. Esta escala se define para reducir el coste computacional manteniendo un buen nivel de representatividad.

Los agentes representan usuarios básicos o *premium* del total de usuarios de la aplicación, dependiendo del ratio inicial de usuarios *premium*  $\alpha$  sobre el total de usuarios. Durante la inicialización del modelo, cada agente es inicializado como usuario básico o *premium* aleatoriamente. Debido a la aleatoriedad del modelo cada ejecución puede resultar en distintos patrones de difusión y resultados finales, por lo que usamos simulaciones de Monte-Carlo (MC) y ejecutamos múltiples veces la simulación. Cada agente toma decisiones asincrónicamente, es decir, sin mecanismos de sincronización con el resto de agentes, dado que así el modelo se asemeja más a un modelo de simulación continuo, más cercano a la realidad [12].

### B. Actualización del estado de los agentes y de su red

Los agentes tienen distintas variables de estado para representar la transición de usuario básico a *premium*. En el

modelo un usuario pasa de básico a *premium* cuando compra en la tienda *in-game*. No consideraremos la transición inversa (esto es, dejar de ser *premium* para ser básico, *churn*), dado que no hay datos disponibles y no podríamos calibrar este comportamiento.

Cada agente tiene un conjunto de enlaces que representan las relaciones sociales entre usuarios de la aplicación. Estas relaciones son enlaces unidireccionales que habilitan el intercambio de información y canalizan influencias entre ellos. Los enlaces de la red social se generan usando un algoritmo basado en un grado de distribución dado [15], [25], con un grado medio de 48,19 usuarios y una densidad de 0,0024.

En cada paso del modelo, cada agente primero decide si jugar o no siguiendo una probabilidad que depende del día de la semana. Modelamos este comportamiento usando dos parámetros: (a) la probabilidad de jugar entre semana ( $d \in [0, 1]$ ) y (b) la probabilidad de jugar en fin de semana ( $f \in [0, 1]$ ). Si un agente juega a la aplicación, podrá decidir posteriormente si adoptar contenido *premium* en base a la influencia social de sus contactos (imitación) o por su propia iniciativa (innovación). Este proceso de adopción sigue el modelo de Bass [12], [16], descrito en la Sección II-C. La probabilidad de jugar de cada agente sigue la Ecuación 1. El agente  $A$  decide jugar el día  $t$  si la función  $jugar_t^A(r)$  devuelve 1, donde  $r \in [0, 1]$  es un número aleatorio generado usando una distribución uniforme.

$$jugar_t^A(r) = \begin{cases} 1, & \text{si } r < d \wedge t \in \text{entre-semana}, \\ 1, & \text{si } r < f \wedge t \in \text{fin-semana}, \\ 0, & \text{e.o.c.} \end{cases} \quad (1)$$

### C. Modelo de adopción

El modelo de adopción elegido es la versión ABM del modelo de Bass [8], [16]. En el modelo de adopción de Bass, un agente básico puede hacerse *premium* con una probabilidad que incluye tanto el efecto de la publicidad (externalidad) como el de la influencia social o boca a boca. La probabilidad de que un agente se haga *premium* debida a la interacción con otros agentes se regula por la fracción de sus vecinos que se han hecho *premium* en los pasos anteriores. Por tanto, en cada paso un agente básico  $i$  puede hacerse *premium* debido a dos circunstancias:

1. Innovación: con probabilidad  $\hat{p}$  (coeficiente de innovación),  $\hat{p} \in (0, 1)$ , un agente básico puede hacerse *premium* debido a información externa a la red.
2. Imitación: con probabilidad  $\hat{q}$  (coeficiente de imitación),  $\hat{q} \in (0, 1)$ , un agente básico puede hacerse *premium* observando el estado de sus vecinos, donde  $f$  es la fracción de vecinos *premium*.

En estas circunstancias podemos modelar el proceso de adopción *premium* siguiendo la Ecuación 2 [12]. Un agente  $A$  puede hacerse *premium* en un step  $t$  si *adoptar* devuelve 1, donde  $r, s \in [0, 1]$  son números aleatorios generados usando una distribución uniforme y  $f_A$  es la fracción de vecinos *premium* de  $A$ .



$$\text{adoptar}_t^A(r, s) = \begin{cases} 1, & \text{si } r < \hat{p} \vee s < f_A \hat{q}, \\ 0, & \text{e.o.c.} \end{cases} \quad (2)$$

### III. METAHEURÍSTICAS PARA CALIBRACIÓN

En esta sección presentamos nuestra propuesta para calibrar ABM usando métodos automáticos basados en metaheurísticas. La calibración automática es un proceso intensivo que usa una medida de error para comparar la salida del modelo con datos reales, modificando sus parámetros para encontrar la configuración que más se ajuste a los datos reales [17], [18]. Medimos la calidad del modelo ejecutando una simulación y comparando su salida con los datos reales. En este trabajo hemos considerado metaheurísticas para calibración dado que los parámetros del ABM no muestran interacciones lineales y la mejor opción es usar un algoritmo de optimización no-lineal que pueda gestionar un espacio de búsqueda muy amplio [17], [26], [27]. Aun así, elegir la metaheurística más adecuada para calibrar ABM no es trivial dado que hay que tener en cuenta dos criterios opuestos: la exploración del espacio de búsqueda (diversificación) y la explotación de las soluciones más prometedoras (intensificación).

En general, las metaheurísticas elegidas modificarán el conjunto de parámetros del modelo para ajustarse a los datos reales de las distintas instancias. Calibramos cuatro parámetros reales del modelo anteriormente descrito: los dos parámetros que regulan la estacionalidad  $d, f \in [0, 1]$ , el coeficiente de innovación  $\hat{p} \in [0, 1]$ , y el coeficiente de imitación  $\hat{q} \in [0, 1]$ . Las metaheurísticas seleccionadas usan la misma función de *fitness*, que determina la calidad del modelo con relación a los datos reales de usuarios *premium*. Para evaluar el ajuste de un modelo utilizamos cada *dataset*  $R$  y lo dividimos en  $R_{train}$  y  $R_{test}$  para seguir un enfoque de validación *hold-out* [27]. Ambos conjuntos tienen sus variables de entorno correspondientes  $E_{train}$  y  $E_{test}$ , que definen las condiciones como el estado de la red social y el número de usuarios *premium*. Utilizaremos 15 ejecuciones de MC, siendo la estimación de error  $\epsilon(R_{train}, M(P^*, E_{train}))$  la media del ajuste en estas 15 ejecuciones de la simulación. En nuestro caso elegimos  $L^2$  o distancia euclídea para calcular el error  $\epsilon$ :

$$L^2 = \sqrt{\sum_{i=0}^{n-1} |V_M(i) - V_R(i)|^2},$$

donde  $n$  es el número de puntos del histórico y  $V_M$  y  $V_R$  son los vectores de salida (nuevos usuarios *premium*) del modelo y de la instancia respectivamente. Por último, hemos implementado las metaheurísticas en Java utilizando el *framework* ECJ [28]. Las secciones siguientes presentan los detalles de las metaheurísticas elegidas: *hill climbing* [19], algoritmos genéticos [20], *differential evolution* [21], *PSO* [22], y *CMA-ES* [23].

#### A. HC

Hemos definido una búsqueda local para comparar su rendimiento con las metaheurísticas poblacionales. Nuestro pro-

cedimiento de búsqueda local implementa una estrategia tipo *hill climbing* [19]. Partiendo de una solución aleatoria, refina la calidad de la solución incrementando o decrementando el valor de uno de los parámetros de manera iterativa. Nuestra búsqueda local considera la variable *incremento*, que regula la variación aplicada a los parámetros de la solución. En cada iteración, la búsqueda local se moverá al primer vecino que mejore su *fitness* por un *umbral* dado.

#### B. GA

Diseñamos nuestro algoritmo genético (GA) siguiendo una estrategia generacional donde cada nueva generación reemplaza a la anterior [20]. Fijamos el tamaño de población del algoritmo en 100 individuos y el número de generaciones en 200. Nuestra implementación usa selección por torneo [19], con  $k$  siendo el tamaño del torneo. También incluimos elitismo débil, por lo que el mejor padre siempre pasa a la siguiente generación. Como estrategia de cruce elegimos un cruce multipunto *PMX* con probabilidad  $p_c$  para cada individuo. Respecto a la estrategia de mutación, cada individuo tendrá una probabilidad  $p_m$  de reiniciar uno de sus parámetros (genes), sustituyendo su valor por un número aleatorio usando una distribución uniforme en el intervalo  $[0, 1]$ .

#### C. PSO

Para nuestra implementación de *Particle Swarm Optimization* (PSO) [22] consideramos también una población de 100 individuos y 200 iteraciones. Cada individuo considera 5 vecinos que se asignan aleatoriamente durante la inicialización del algoritmo. En cada iteración, cada individuo se mueve (modifica sus valores) considerando su mejor configuración conocida, el mejor de sus vecinos, y el mejor global. Este movimiento se calcula utilizando cuatro parámetros que actúan como pesos: velocidad ( $v_c$ ), mejor personal ( $p_c$ ), mejor vecino ( $i_c$ ), y mejor global ( $g_c$ ).

#### D. DE

El diseño que hemos elegido para *differential evolution* (DE) [21] considera una población de 100 individuos y se ejecuta durante 200 generaciones. La variante utilizada es *DE/rand/2*, que genera el vector donante a partir de la siguiente ecuación:  $x_i(G+1) = x_{r1}(G) + F(x_{r2}(G) - x_{r3}(G))$ , donde  $x_i$  es el vector generado y  $r1$ ,  $r2$ , y  $r3$  son soluciones diferentes.  $F$  es un parámetro del algoritmo que actúa de amplificador de la mutación. Esta variante genera nuevos individuos usando el vector donante con una probabilidad definida por el parámetro *CR*.

#### E. CMA-ES

*Covariance matrix adaptation evolution strategy* (CMA-ES) [23] es otro algoritmo bio-inspirado que desarrolla la mutación de su población (o recombinación) de acuerdo a una matriz de covarianza. CMA-ES suele funcionar muy bien con problemas similares al nuestro, ya que los parámetros son valores reales y el tamaño del conjunto a calibrar es pequeño. Hemos elegido la variante  $(\mu/\mu_I, \lambda)$ -CMA-ES, donde en cada iteración se combinan los mejores  $\mu$  candidatos con  $\lambda$  nuevas soluciones.

## IV. EXPERIMENTACIÓN

## A. Configuración

La Tabla I muestra los parámetros que hemos usado para nuestros experimentos. Nuestro proceso de calibración considera datos reales de *Creature Party* divididos en cuatro datasets diferentes. Estos datasets contienen el número de usuarios premium por día para periodos de tiempo distintos que a su vez dividimos en *training* y *test*. El primer dataset contiene 91 días, con 60 para *training* y 31 para *test*. El segundo y el tercer dataset consideran 46 días, divididos en 31 días para *training* y 15 para *test*. El cuarto y último dataset contiene 45 días, con 30 para *training* y 15 para *test*.

Tabla I: Valores de los parámetros de las metaheurísticas

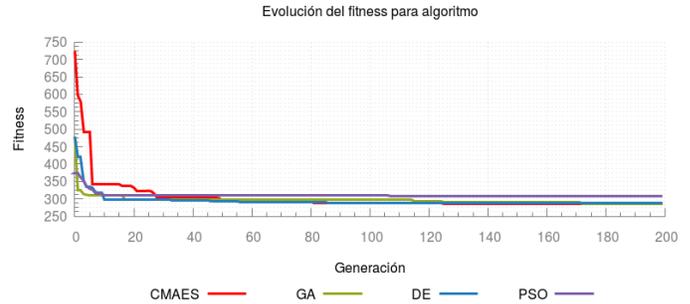
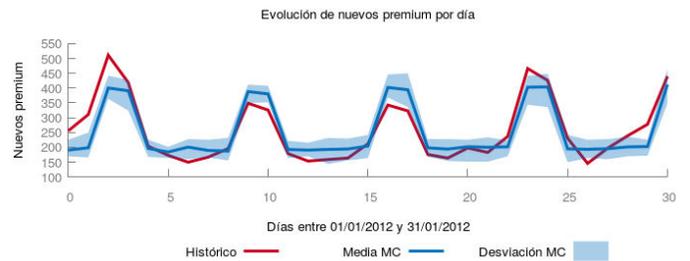
General		GA		PSO	
Nombre	Valor	Nombre	Valor	Nombre	Valor
Evaluaciones	20,000	$p_c$	1.0	$v_c$	0.3
Individuos	100	$p_m$	0.2	$p_c$	0.04
Generaciones	200	$k$	3	$i_c$	0.3
Monte-Carlo	15			$g_c$	0.3
HC		DE		CMA-ES	
Nombre	Valor	Nombre	Valor	Nombre	Valor
$incremento$	0.01	$F$	0.6	$\lambda$	8
$umbral$	0.01	$CR$	0.3	$\mu$	4

## B. Resultados de calibración

Mostramos los resultados de calibración obtenidos por las metaheurísticas en la Tabla II. Estos resultados muestran el ajuste de la mejor solución después de 15 ejecuciones con distintas semillas. Este ajuste se presenta como el *fitness* medio y la desviación típica de las 15 simulaciones de MC para *training* y *test*. Como se puede observar, el *fitness* de la mayoría de metaheurísticas es mejor para los datasets más pequeños (2, 3, y 4), lo cual parece coherente dado que su comportamiento debería ser más fácil de ajustar. Por otro lado, los valores de desviación típica son similares. Con respecto al ajuste de las soluciones, estos resultados muestran que CMA-ES supera a los otros algoritmos por un pequeño margen. Además de valores de *fitness* bajos, CMA-ES consigue unos valores de desviación típica reducidos, por lo que se muestra estable con distintas semillas.

Mostramos el rendimiento de los algoritmos poblacionales durante el proceso de calibración usando el dataset 3 en la Figura 1. Esta gráfica muestra la evolución del *fitness* de la mejor solución en cada generación, por lo que el progreso de los algoritmos se muestra cada 100 evaluaciones. Estos resultados muestran que los algoritmos alcanzan valores de error reducidos rápidamente y sugieren que aumentar el número de evaluaciones no mejoraría el resultado final de manera significativa.

En la Figura 2 mostramos una comparación entre los datos históricos y la salida del modelo calibrado para la mejor solución encontrada por CMA-ES para el segmento *training* del dataset 2. Estos resultados muestran que el proceso de calibración obtiene buenos resultados y que el modelo calibrado


 Figura 1: Evolución del *fitness* de los algoritmos poblacionales para el dataset 3.

 Figura 2: Comparación entre la salida del modelo calibrado y los datos históricos de *training* del dataset 2 (31 días).

se ajusta a los datos históricos. Por ejemplo en el step 4, el número de usuarios *premium* fue 204 y la simulación predice 196. Aunque hay excepciones, como el día 2 donde el número de usuarios *premium* fue 511 pero el modelo predice 404.

## C. Análisis de sensibilidad

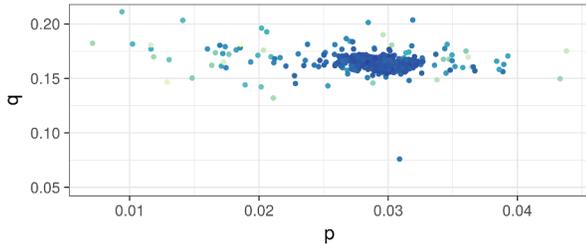
Nuestros experimentos señalan CMA-ES como el mejor método, consiguiendo los mejores resultados en tres conjuntos de *training* y uno de *test*. En esta sección hacemos un análisis de sensibilidad a las soluciones generadas por CMA-ES para cada dataset. Los *scatter plots* de las Figuras 3 y 4 muestran los valores de los coeficientes de Bass y los parámetros de estacionalidad para las soluciones generadas por CMA-ES durante el proceso de calibración. Estas soluciones provienen de una única ejecución de la metaheurística, recogidas desde el principio de la calibración hasta que el algoritmo termina, filtrando las soluciones que superen 500 de *fitness*. Este filtro permite concentrar el análisis en las mejores soluciones.

Podemos observar que los valores de los coeficientes de Bass de las soluciones para los distintos dataset son similares. Por ejemplo, para el primer dataset (Figura 3a) las mejores soluciones rondan  $\hat{p} = 0,03$  y  $\hat{q} = 0,16$ . En cambio el coeficiente de imitación es ligeramente más bajo en el resto de datasets ( $\hat{q} = 0,1$ ). En el caso del coeficiente de innovación, los dos primeros dataset (Figura 3a y 3b) muestran sus mejores valores alrededor de  $\hat{p} = 0,03$  y los dos siguientes (Figura 3c y 3d) alrededor de  $\hat{p} = 0,045$ . En estos últimos observamos también mayor dispersión en sus soluciones con

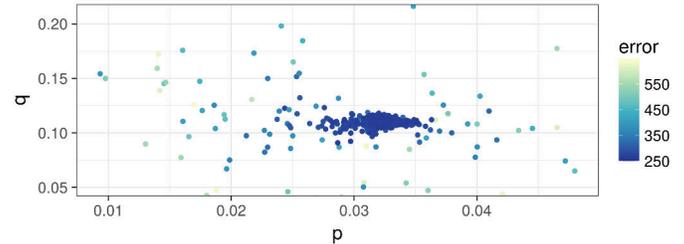


Tabla II: Fitness medio y desviación típica de cada metaheurística para cada dataset

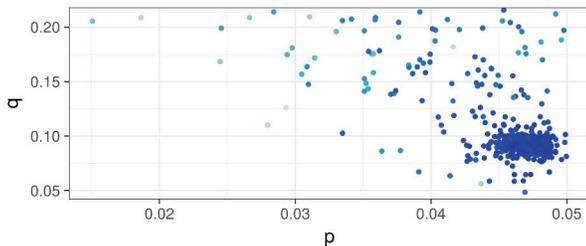
	Dataset 1		Dataset 2		Dataset 3		Dataset 4	
	TRA	TEST	TRA	TEST	TRA	TEST	TRA	TEST
<b>HC</b>	365.6 (18.7)	349.2 (21.9)	256.0 (17.2)	211.0 (20.3)	301.1 (19.8)	351.7 (15.7)	336.1 (30.3)	<b>222.1 (20.1)</b>
<b>GA</b>	351.9 (19.6)	333.7 (22.4)	247.6 (24.8)	182.1 (19.1)	286.0 (22.4)	331.4 (20.0)	304.5 (26.0)	283.7 (31.5)
<b>DE</b>	351.8 (18.9)	335.3 (20.4)	<b>245.3 (22.0)</b>	194.8 (20.5)	286.8 (21.6)	348.0 (17.0)	<b>301.6 (17.6)</b>	283.5 (34.2)
<b>PSO</b>	347.2 (15.0)	332.5 (20.8)	246.1 (13.8)	191.7 (19.5)	308.0 (19.7)	<b>261.5 (22.7)</b>	316.5 (31.5)	365.2 (20.4)
<b>CMA-ES</b>	<b>326.9 (18.2)</b>	<b>296.4 (15.6)</b>	248.1 (13.9)	<b>164.8 (17.0)</b>	<b>286.0 (16.9)</b>	318.1 (22.3)	303.3 (24.4)	267.2 (26.4)



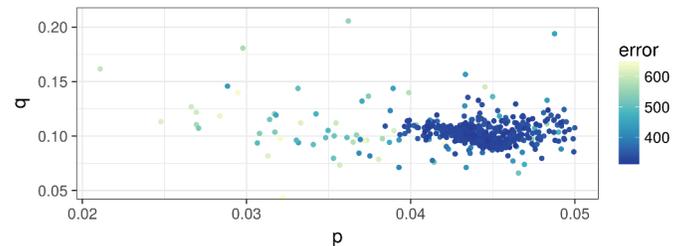
(a) Dataset 1



(b) Dataset 2



(c) Dataset 3



(d) Dataset 4

Figura 3: Scatter plots para el análisis de sensibilidad sobre los coeficientes de Bass ( $p/q$ ).

mejor *fitness*, lo que podría indicar que estos dataset tienen mayor tolerancia a distintos valores de estos parámetros. Globalmente, se puede observar que las soluciones muestran mayor dispersión para el coeficiente de innovación ( $\hat{p}$ ), lo que indica que es un parámetro más sensible. En comparación con otras configuraciones del modelo de Bass para otros mercados publicados anteriormente en la literatura de marketing [12], los modelos calibrados presentan un valor alto para el coeficiente de innovación ( $\hat{p}$ ) y un valor bajo para el coeficiente de imitación ( $\hat{q}$ ).

Por último, los *scatter plots* de la Figura 4 muestran los valores de estacionalidad para las soluciones encontradas para los distintos datasets. Estas soluciones muestran valores constantes en los diferentes datasets, con valores que rondan  $d=0,1$  para la probabilidad de jugar entre semana y  $f=0,2$  para la probabilidad de jugar en fin de semana. Estos parámetros también muestran mayor concentración en el parámetro ( $d$ ), lo que sugiere que el ABM de *Creature Party* es más sensible a los cambios en la probabilidad de jugar entre semana que en para la probabilidad de jugar en el fin de semana.

## V. CONCLUSIONES

En este artículo hemos aplicado distintas metaheurísticas a la calibración de un modelo ABM usando datos reales. Después de comparar el rendimiento de los algoritmos, hemos

elegido las soluciones calibradas por CMA-ES, la mejor metaheurística según nuestra experimentación, para desarrollar un análisis de sensibilidad sobre sus parámetros. Usando estas soluciones, hemos visualizado los valores de los coeficientes del modelo de Bass y los parámetros de estacionalidad.

Los resultados de calibración de las distintas metaheurísticas muestran valores de *fitness* cercanos. Sin embargo, CMA-ES consigue mejores soluciones por lo que lo distinguimos como el mejor método, lo cual es coherente con publicaciones anteriores sobre optimización continua utilizando metaheurísticas.

El análisis de sensibilidad aplicado sobre las soluciones calibradas por CMA-ES muestra que sus parámetros para los distintos dataset son similares. Además estos valores son diferentes de otros modelos similares [12], lo que podría indicar que las aplicaciones *freemium* como *Creature Party* tienen un componente de innovación mayor. Por último, dado que nuestro análisis no tiene en cuenta las características específicas del diseño del ABM subyacente, pensamos que nuestros resultados podrían ser generalizables a otros modelos.

## AGRADECIMIENTOS

Este trabajo está financiado por el Ministerio de Economía y Competitividad bajo el proyecto NEWSOCO (ref. TIN2015-67661-P), incluyendo Fondos Europeos de Desarrollo Regional (ERDF).

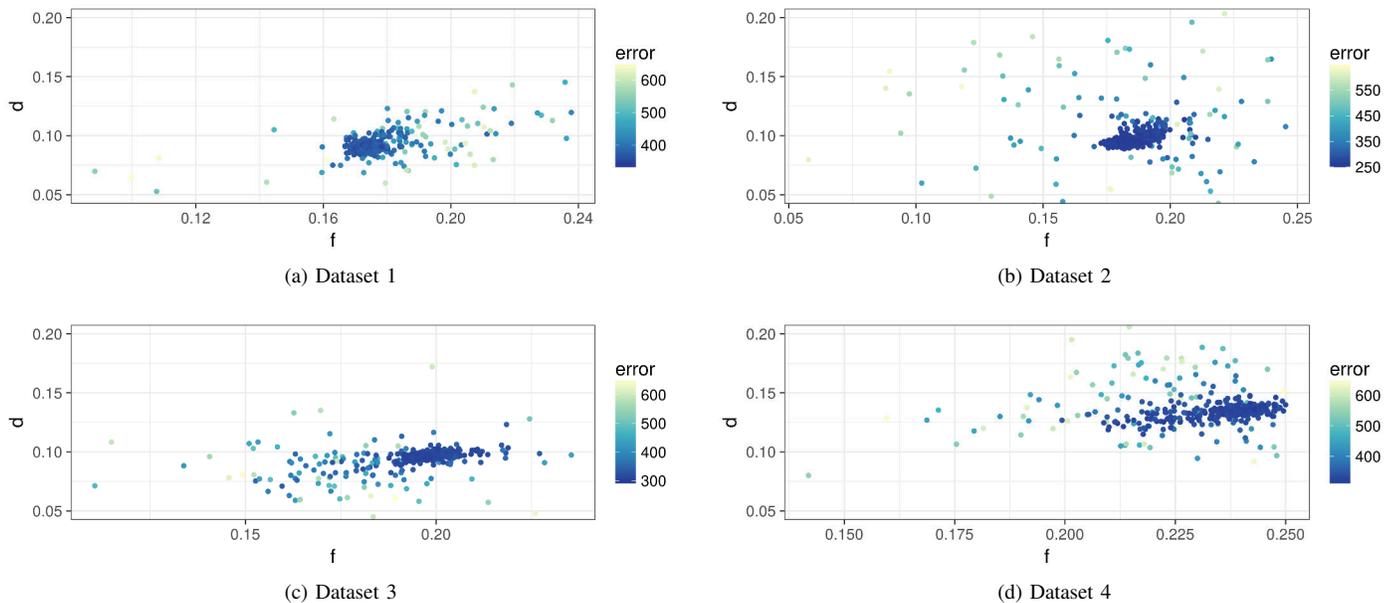


Figura 4: Scatter plots con los valores de los parámetros de estacionalidad: entre semana ( $d$ ) y fin de semana ( $f$ ).

#### REFERENCIAS

- [1] V. Kumar, "Making freemium work: Many start-ups fail to recognize the challenges of this popular business model." *Harvard Business Review*, vol. 92, no. 5, pp. 27–29, May 2014. [Online]. Available: <https://hbr.org/2014/05/making-freemium-work>
- [2] M. Trusov, R. E. Bucklin, and K. Pauwels, "Effects of word-of-mouth versus traditional marketing: Findings from an internet social networking site," *Journal of Marketing*, vol. 73, no. 5, pp. 90–102, 2009.
- [3] B. Libai, R. Bolton, M. S. Bügel, K. De Ruyter, O. Götz, H. Risselada, and A. T. Stephen, "Customer-to-customer interactions: broadening the scope of word of mouth research," *Journal of Service Research*, vol. 13, no. 3, pp. 267–282, 2010.
- [4] O. Hinz, B. Skiera, C. Barrot, and J. U. Becker, "Seeding strategies for viral marketing: An empirical comparison," *Journal of Marketing*, vol. 75, no. 6, pp. 55–71, 2011.
- [5] R. Van der Lans, G. Van Bruggen, J. Eliashberg, and B. Wierenga, "A viral branching model for predicting the spread of electronic word of mouth," *Marketing Science*, vol. 29, no. 2, pp. 348–365, 2010.
- [6] D. J. Watts and P. S. Dodds, "Influentials, networks, and public opinion formation," *Journal of Consumer Research*, vol. 34, no. 4, pp. 441–458, 2007.
- [7] P. Schmitt, B. Skiera, and C. Van den Bulte, "Referral programs and customer value," *Journal of Marketing*, vol. 75, no. 1, pp. 46–59, 2011.
- [8] M. Chica and W. Rand, "Building agent-based decision support systems for word-of-mouth programs: A freemium application," *Journal of Marketing Research*, vol. 54, no. 5, pp. 752–767, 2017. [Online]. Available: <https://doi.org/10.1509/jmr.15.0443>
- [9] C. M. Macal and M. J. North, "Tutorial on agent-based modeling and simulation," in *Proceedings of the 37th conference on Winter simulation*. ACM, 2005, pp. 2–15.
- [10] J. M. Epstein, *Generative social science: Studies in agent-based computational modeling*. Princeton University Press, 2006.
- [11] M. A. Janssen and E. Ostrom, "Empirically based, agent-based models," *Ecology and Society*, vol. 11, no. 2, p. 37, 2006.
- [12] W. Rand and R. T. Rust, "Agent-based modeling in marketing: Guidelines for rigor," *International Journal of Research in Marketing*, vol. 28, no. 3, pp. 181–193, 2011.
- [13] M. Trusov, W. Rand, and Y. V. Joshi, "Improving prelaunch diffusion forecasts: Using synthetic networks as simulated priors," *Journal of Marketing Research*, vol. 50, no. 6, pp. 675–690, 2013.
- [14] M. Haenlein and B. Libai, "Targeting revenue leaders for a new product," *Journal of Marketing*, vol. 77, no. 3, pp. 65–80, 2013.
- [15] F. Viger and M. Latapy, "Efficient and simple generation of random simple connected graphs with prescribed degree sequence," in *Lecture Notes in Computer Science. Computing and Combinatorics*. Springer, 2005, vol. 3595, pp. 440–449.
- [16] F. M. Bass, "A new product growth model for consumer durables," *Management Science*, vol. 36, no. 9, pp. 1057–1079, 1969.
- [17] R. Oliva, "Model calibration as a testing strategy for system dynamics models," *European Journal of Operational Research*, vol. 151, no. 3, pp. 552–568, 2003.
- [18] R. G. Sargent, "Verification and validation of simulation models," in *Proceedings of the 37th conference on Winter simulation*, 2005, pp. 130–143.
- [19] E.-G. Talbi, *Metaheuristics: from design to implementation*. John Wiley & Sons, 2009.
- [20] T. Back, D. B. Fogel, and Z. Michalewicz, *Handbook of evolutionary computation*. Bristol (UK): IOP Publishing Ltd., 1997.
- [21] K. Price, R. M. Storm, and J. A. Lampinen, *Differential evolution: a practical approach to global optimization*. Springer Science & Business Media, 2006.
- [22] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Neural Networks, 1995. Proceedings., IEEE International Conference on*, vol. 4. IEEE, 1995, pp. 1942–1948.
- [23] N. Hansen and A. Ostermeier, "Completely derandomized self-adaptation in evolution strategies," *Evolutionary computation*, vol. 9, no. 2, pp. 159–195, 2001.
- [24] P. W. Farris, N. T. Bendle, P. E. Pfeifer, and D. J. Reibstein, *Marketing metrics: The definitive guide to measuring marketing performance*, 2nd ed. Wharton School Publishing, 2010.
- [25] R. Milo, N. Kashtan, S. Itzkovitz, M. Newman, and U. Alon, "On the uniform generation of random graphs with prescribed degree sequences," *arXiv preprint <http://arxiv.org/abs/cond-mat/0404015>*, 2004.
- [26] J. H. Miller, "Active nonlinear tests (ANTs) of complex simulation models," *Management Science*, vol. 44, no. 6, pp. 820–830, 1998.
- [27] F. Stonedahl and W. Rand, "When does simulated data match real data? Comparing model calibration functions using genetic algorithms," in *Advances in Computational Social Science*, ser. Agent-Based Social Systems. Springer, Japan, 2014, vol. 11, pp. 297–313.
- [28] S. Luke, L. Panait, G. Balan, S. Paus, Z. Skolicki, J. Bassett, R. Hubley, and A. Chircop, "Ecj: A java-based evolutionary computation research system," *Downloadable versions and documentation can be found at the following url: <http://cs.gmu.edu/eclab/projects/ecj>*, 2006.



# An empirical validation of a new memetic CRO algorithm for the approximation of time series\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Antonio M. Durán-Rosal

*Dept. of Computer Science and Numerical Analysis*  
*University of Córdoba*  
Córdoba, Spain  
aduran@uco.es

Pedro A. Gutiérrez

*Dept. of Computer Science and Numerical Analysis*  
*University of Córdoba*  
Córdoba, Spain  
pagutierrez@uco.es

Sancho Salcedo-Sanz

*Department of Signal Processing and Communications*  
*Universidad de Alcalá*  
Madrid, Spain  
sancho.salcedo@uah.es

César Hervás-Martínez

*Dept. of Computer Science and Numerical Analysis*  
*University of Córdoba*  
Córdoba, Spain  
chervas@uco.es

**Abstract**—The exponential increase of available temporal data encourages the development of new automatic techniques to reduce the number of points of time series. In this paper, we propose a novel modification of the coral reefs optimization algorithm (CRO) to reduce the size of the time series with the minimum error of approximation. During the evolution, the solutions are locally optimised and reintroduced in the optimization process. The hybridization is performed using two well-known state-of-the-art algorithms, namely Bottom-Up and Top-Down. The resulting algorithm, called memetic CRO (MCRO), is compared against standard CRO, its statistically driven version (SCRO) and their hybrid versions (HCRO and HSCRO, respectively). The methodology is tested in 15 time series collected from different sources, including financial problems, oceanography data, and cardiology signals, among others, showing that the best results are obtained by MCRO.

**Index Terms**—Time series size reduction, segmentation, coral reefs optimization, memetic algorithms

# Modelling Mandible Articulation for Skull-Face Overlay in Forensic Identification<sup>1</sup>

E. Bermejo, C. Campomanes-Álvarez,  
A. Valsecchi, O. Ibáñez, and S.Damas

\*Andalusian Institute on Data Science and Computational  
Intelligence (DaSCI), University of Granada  
Email: enrique.bermejo@decsai.ugr.es, sdamas@ugr.es

O. Cordon\*

Research Center on Information  
and Communication Technologies  
University of Granada  
Email: ocordon@decsai.ugr.es

## I. INTRODUCTION

*Forensic anthropology* is a sub-field of physical anthropology that involves applying scientific knowledge to the collection and analysis of medico-legal information. It includes the recovery, identification, and description of human skeletal remains [2]. Currently, several forensic identification techniques are available, i.e., DNA samples, fingerprint recognition, or dental records. When none of the previous methods can be applied, the analysis of skeletal remains becomes the last resort of forensic identification. One of the alternative techniques is craniofacial superimposition (CFS) [3], which involves the superimposition of a complete skull (or a skull model) with a number of *ante mortem* (AM) images of an individual. CFS is thus a technique used when only skeletal information is available for the forensic assessment and other techniques such as DNA or dental record analysis are not possible or conclusive.

Traditional CFS techniques are tedious and based on a ‘trial and error’ process requiring several hours of manual processing to obtain a correct superimposition. Therefore, there is a strong interest on designing automatic methods to assist the CFS identification procedure [4]. The process requires a forensic expert to position the skull in the same pose as the face in the photograph. This process is known as Skull-Face Overlay (SFO).

Up to now, all computer-based SFO methods have considered the mandible as a rigid part of the skull. These methods usually follow one of the following approaches to approximate the mandible aperture [5]: i) Before capturing the 3D model, the mandible was manually located relative to the cranium so that the model resembled the facial expression of the photograph under study; and ii) Once the mandible and the cranium were scanned, the 3D models were positioned according to the relative aperture in the photograph using 3D modeling software.

Such a simplification (*anatomically incorrect*) causes a negative impact on the accuracy of the automatic SFO method. As the AM images used to perform CFS are typically provided

by relatives, the missing person usually appears in relaxed situations, most of them smiling or with the mouth slightly open. Generally, cases with grimaces or forced poses are discarded due to the fact that the mandible is in an exaggerated position and these kinds of facial expressions distort the soft tissue of the face. Additionally, each individual comparison should involve the analysis of one skull against more than one AM photograph of the same person to significantly increase the reliability and accuracy of the method [6]. Overall, this is a very time-consuming task even using an automatic SFO method.

## II. MOTIVATION, PROPOSAL, AND CONCLUSIONS

Those photographs where subjects appear with their mouths open reduce the confidence of the identification. Therefore, it is essential to model the articulation of the mandible in order to improve CFS reliability, considering that we only have skeletal information available to infer its movement. In our contribution, we have modeled and integrated the mandible articulation within the SFO optimization algorithm.

In particular, we considered a simple model [7] to estimate and parameterize the mandible aperture movement using the aperture percentage. Moreover, we proposed different design alternatives to integrate the estimation of the mandible aperture within the scheme of the current state-of-the-art SFO optimization algorithm [8], namely RCGA. Specifically, RCGA is a real-coded, elitist genetic algorithm that performs the registration of the 3D skull with the 2D AM photograph.

Our proposal involves three different design alternatives to balance the exploration-exploitation trade-off during the optimization. We have performed a thorough experimental study to analyze the suitability of the proposed articulation model to the SFO technique. Additionally, we have designed a ground-truth database to allow an objective evaluation of the reliability of our proposal.

According to the results of this experimentation (Figure 1), the application of a simple mandible aperture model has proven its effectiveness, significantly improving the accuracy and the versatility of the state-of-the-art automatic SFO method. Such an outstanding performance facilitates the use of facial photos where the individual either smiles or opens the mouth partially. Such photos have been usually discarded

<sup>1</sup> This article is a summary of the work published in Information Sciences [1], to be considered as a part of the CAEPIA'18 Key Works. The motivation, the main contributions and some conclusions are briefly summarized.



in real identification scenarios. The availability of new AM evidence is a crucial consequence of this work. Indeed, the use of multiple facial photos of the same individual is essential to increase the reliability of the identification based in CFS [9]

In our proposal, the expert is only required to pinpoint the incisors, and the mandibular and cranial condyles, a much simpler task to carry out. This task is only performed once, no matter which number of AM photos the skull is compared with. Thereby, our articulated SFO approach avoids entirely the time-consuming and error-prone positioning of the mandible, besides adding versatility to the procedure as it can adapt its pose to different mouth openings in the photographs.

#### ACKNOWLEDGMENT

This publication is supported by Spanish Ministerio de Economía y Competitividad under the NEWSOCO project (ref. TIN2015-67661-P) and the Andalusian Dept. of Innovación, Ciencia y Empresa under project TIC2011-7745, both including European Regional Development Funds (ERDF). Dr. C. Campomanes Álvarez's work has been supported by Spanish MECD FPU grant AP-2012-4285. Dr. Ibáñez's work has been supported by Spanish MINECO Juan de la Cierva Fellowship JCI-2012-15359.

#### REFERENCES

- [1] E. Bermejo, C. Campomanes-Álvarez, A. Valsecchi, O. Ibáñez, S. Damas, and O. Cordón, "Genetic algorithms for skull-face overlay including mandible articulation," *Information Sciences*, vol. 420, pp. 200 – 217, 2017.
- [2] M. Yoshino and S. Seta, "Skull-photo superimposition," *Encyclopedia of Forensic Sciences*, vol. 2, pp. 807–815, 2000.
- [3] M. Yoshino, *Craniofacial superimposition*, in: C. Wilkinson and C. Rynn, Eds. Craniofacial Identification, University Press, Cambridge, 2012.
- [4] S. Damas, O. Cordón, O. Ibáñez, J. Santamaría, I. Alemán, M. Botella, and F. Navarro, "Forensic identification by computer-aided craniofacial superimposition," *ACM Computing Surveys*, vol. 43, no. 4, pp. 1–27, 2011.
- [5] M. I. Huete, O. Ibáñez, C. Wilkinson, and T. Kahana, "Past, present, and future of craniofacial superimposition: Literature and international surveys," *Legal Medicine*, vol. 17, no. 4, pp. 267–278, 2015.
- [6] S. Damas, C. Wilkinson, T. Kahana, E. Veselovskaya, A. Abramov, R. Jankauskas, P. T. Jayaprakash, E. Ruiz, F. Navarro, M. I. Huete, E. Cunha, F. Cavalli, J. Clement, P. Lestón, F. Molinero, T. Briers, F. Viegas, K. Imaizumi, D. Humpire, and O. Ibáñez, *Study on the performance of different craniofacial superimposition approaches (II): Best practices proposal*. Forensic Science International, 2015, vol. 257.
- [7] J. J. Lemoine, J. J. Xia, C. R. Andersen, J. Gateno, W. Buford, and M. A. K. Liebschner, "Geometry-Based Algorithm for the Prediction of Nonpathologic Mandibular Movement," *Journal of Oral and Maxillofacial Surgery*, vol. 65, no. 12, pp. 2411–2417, 2007.
- [8] B. R. Campomanes-Alvarez, O. Ibanez, C. Campomanes-Alvarez, S. Damas, and O. Cordón, "Modeling Facial Soft Tissue Thickness for Automatic Skull-Face Overlay," *IEEE Transactions on Information Forensics and Security*, vol. 10, no. 10, pp. 2057–2070, oct 2015.
- [9] D. Austin-Smith and W. R. Maples, "The reliability of skull/photograph superimposition in individual identification," *Journal of Forensic Sciences*, vol. 39, no. 2, pp. 446–55, mar 1994.

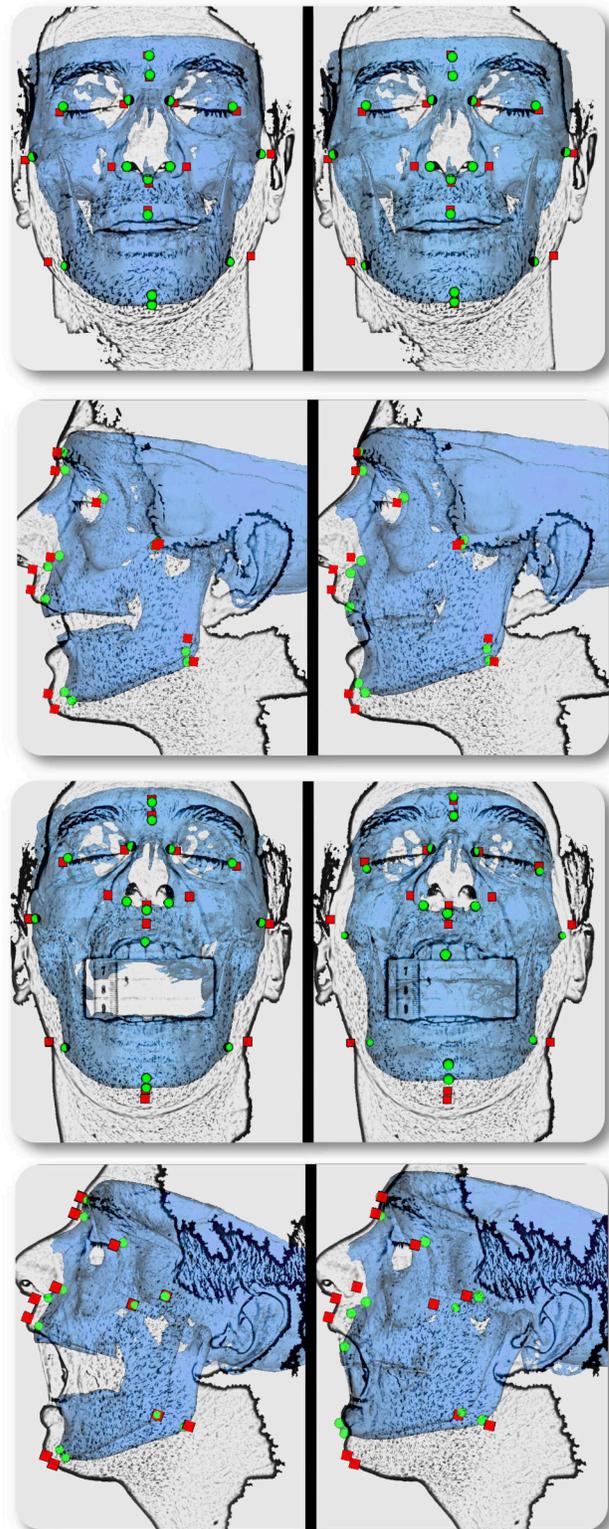


Fig. 1. Visual SFO results: A1 (left images) and RCGA (right images) for different frontal and lateral instances (Smile, 15, 30, and 40).

# Propuestas de mejora para la evaluación del arte evolutivo.

Francisco Fernández de Vega<sup>1</sup>, Cayetano Cruz<sup>1</sup>, Patricia Hernández<sup>2</sup>

## I. RESUMEN

En este trabajo se discute el modo de evaluar adecuadamente el arte evolutivo, no tanto desde el punto de vista de la función de fitness, que también, sino considerando el resultado final al que se llega. En la aplicación tradicional de los algoritmos evolutivos a la resolución de problemas el resultado obtenido es fácilmente evaluable y comparable con otras metodologías, pues basta obtener una medida cuantitativa de la calidad final de la solución. Sin embargo, en los procesos asociados al arte y diseño, estas medidas objetivas no son tan sencillas. Este trabajo, que se plantea como un posicionamiento sobre la cuestión de cómo evaluar apropiadamente el arte evolutivo, revisa alguna de las propuestas que se han producido en este ámbito, pasando por la evaluación interactiva, el test de turing para el arte así como algunas competiciones internacionales en el dominio de los algoritmos evolutivos, para discutir finalmente el papel que otros actores fundamentales, y frecuentemente olvidados en el mundo del arte, están teniendo en este arte generativo basado en evolución: el público, la crítica, galerías de arte, museos, etc. Una vez discutida la cuestión, y planteada la solución propuesta, se describen algunas experiencias en las que algunos, si no todos, de estos actores han sido incluidos en el proceso, y los resultados que se han obtenido. Entendemos que estas experiencias pueden servir de ejemplo para otras iniciativas artísticas que puedan surgir en este ámbito de aplicación de los algoritmos evolutivos, y a la vez la propuesta sirva para clarificar el papel del arte evolutivo en el contexto artístico en general.

## II. INTRODUCCIÓN

La aplicación de los algoritmos evolutivos al arte y diseño no es nuevo [11]. Desde la década de los noventa, son muchos los trabajos que han utilizado

diferentes variaciones de los algoritmos evolutivos para generar lo que los autores consideran *arte*. De hecho, el arte generativo se ha estado utilizando durante el siglo XX para, basado en medios físicos, químicos, mecánicos o en computadores, generar un nuevo tipo de arte. Ya en los años 60, se organizó en Londres una llamativa exposición en la que arte gráfico, poesía, música, etc, era generada mediante programas de computador [10].

El término *arte* es algo que depende de la sociedad, y ha variado con frecuencia a lo largo de los siglos. Como caso paradigmático de esta variación, cabe destacar el rechazo que el salón de arte de París tuvo hacia los nuevos pintores denominados impresionistas, que decidieron abrir un salón alternativo donde mostrar su obra [6]. En sus inicios, el impresionismo era rechazado por la crítica -compuesta fundamentalmente por los eruditos y artistas más tradicionales de la época, aunque fue recibiendo aceptación del público de forma gradual, y llegó con el tiempo a ser considerado una nueva forma de expresión artística al mismo nivel que el arte más *clásico*. Al impresionismo le siguieron otras muchas tendencias en el siglo XX, como el expresionismo, cubismo, futurismo, dadaísmo, surrealismo, etc. Y es que las formas artísticas trazan líneas que navegan arrastrando esa cadena de colisiones haciendo del arte un lugar activo, positivo, lúcido, versátil y maleable.

Del mismo modo, en el mundo de la música *seria*, los comienzos del siglo XX en Estados Unidos de América vieron nacer una nueva forma de expresión musical fruto del mestizaje de culturas y tradiciones provenientes de varios continentes. La música Jazz, que inicialmente era despreciada como música de *raza* (eufemismo para hablar de personas de color), fue conquistando los gustos del público, y posteriormente, también la crítica musical entendió sus fundamentos e importancia, de tal modo que alguno de los compositores y músicos Jazz de color, son hoy día considerados como alguno de los más grandes artistas y compositores de la historia, incluyendo a Luis Armstrong -trompetista- y Duke Ellington -

<sup>1</sup>Universidad de Extremadura, 06800 Mérida, España.  
fcofdez@unex.es, cacruz@unex.es

<sup>2</sup>Universidad de Sevilla, España  
patriciapahr@gmail.com



pianista-, reconocido actualmente este último como uno de los más grandes compositores americanos de la historia [9].

También lo contrario ha sucedido con frecuencia: tendencias artísticas consideradas desde el inicio como *arte formal* o académico no han sido aceptadas por el público de forma mayoritaria, tal como sucede con el serialismo y dodecafonismo de Schoenberg, que aunque de utilidad innegable asociado a otras formas de arte, como el cine, sigue despertando poco interés entre el público en general [2], y pocas son las compañías, si es que hubiera alguna, que puedan sobrevivir interpretando solamente obras de este tipo sin ayudas del sector público. Quizá sea necesaria una reflexión adicional sobre qué tipo de forma de arte se adapta mejor a la naturaleza intrínseca del ser humano, que es finalmente el destinatario final de la misma, y sobre si el término *arte* se ha desvirtuado o no en el siglo XX y convertido en *cajón de sastre* para incluir elementos que quizá debieran categorizarse de otro modo. Como en otros ámbitos sociales, estirar en demasía el significado de un término pueden provocar que el mismo pierda su contenido semántico. Pero más allá de esta reflexión, conviene aquí considerar el arte evolutivo (y generativo en términos más amplios) en relación al arte humano.

Podemos resumir diciendo, que en la evolución y cambio que el término *arte* ha tenido a lo largo de los siglos, se han visto implicados no sólo los eruditos, que podríamos describir como la *crítica*, sino también el público que con su favor impulsa o no a ciertos artistas, y los museos que acogen y exponen lo que se considera *arte*.

Sin embargo, cuando nos fijamos en los resultados obtenidos mediante procesos evolutivos en el mundo del arte [11] -y centrándonos aquí en el arte plástico- no todos los actores anteriores han sido tenidos en cuenta, como veremos a continuación.

El arte contiene una parte de naturaleza transitoria y circunstancial propia de un determinado espacio tiempo y en este trabajo se pretende revisar la importancia de cada uno de esos actores en el arte evolutivo, y alguno de los resultados más llamativos obtenidos cuando todos los actores participan de algún modo en el proceso.

Este artículo por tanto pretende mostrar el camino hacia una correcta evaluación de trabajos artísticos generados mediante procedimientos basados en algoritmos evolutivos, y describe experiencias recientes que tienen en cuenta la propuesta planteada.

El resto del artículo se estructura del siguiente

modo: La sección III describe las dificultades para evaluar adecuadamente el arte evolutivo. En la sección IV presentamos nuestro posicionamiento al respecto, con ideas sobre como mejorar. La sección V presenta algunos resultados obtenidos mediante la propuesta descrita, y finalmente la sección VI resume nuestras conclusiones.

### III. ESTADO DEL ARTE

Cuando los investigadores decidieron por primera vez aplicar los algoritmos evolutivos en procesos de creación artística, se encontraron un problema, que es la clave en la evaluación del arte a lo largo de la historia: ¿Cómo evaluar correctamente la calidad estética de una imagen surgida de la evolución?

La solución tradicional ha sido permitir que sean los humanos quienes evalúen la calidad, produciendo así un cambio profundo en los algoritmos evolutivos tradicionales, dando lugar a lo que se conocen como Algoritmos Evolutivos Interactivos, con multitud de aplicaciones hoy día [13].

Así, las herramientas que se han desarrollado y están disponibles para el arte evolutivo, tal como PicBreeder, se basan en el buen criterio de las personas a la hora de elegir lo que se considere estéticamente más razonable [12].

Ha habido intentos de encerrar en fórmulas matemáticas la calidad estética de una obra plástica, pero el resultado no ha sido muy afortunado [8]. También se ha intentado evaluar cual es la opinión del público sobre el arte plástico, cuales son sus preferencias, y con un procedimiento basado en encuestas, se llegó a conclusiones poco satisfactorias [3].

Trabajos como este último ponen el dedo en la llaga: la participación de un alto número de usuarios diferentes dando su opinión sobre qué es más apreciado en una obra de arte, cuyo ejemplo más notable es Picbreeder, no tiene necesariamente que conducir a un resultado adecuado.

Pero entonces, si la participación de usuarios no es suficiente para garantizar la calidad del resultado, ¿qué otros elementos sería necesario incluir?

En algunos trabajos recientes se habla de la posibilidad de generar un test de turing para el arte basado en computador [1], que podría aplicarse por tanto al arte evolutivo. Pero precisamente en este modelo hay varios elementos no triviales:

- ¿Quiénes deben actuar como jurado?
- ¿Con qué arte humano comparamos, con el producido por artistas profesionales, o cualquier persona en general?

- El hecho de que un jurado no sepa si una obra ha sido generada por ordenador o no, ¿Le otorga automáticamente un sello de calidad?

Estas son las tres preguntas básicas a las que nos vamos a enfrentar en la siguiente sección, describiendo alguna de las propuestas en las que hemos trabajado en los últimos años, y los resultados que hemos conseguido para intentar proponer modelos más adecuados para el arte evolutivo.

#### IV. METODOLOGÍA: SOBRE LA FORMA DE EVALUAR EL ARTE EVOLUTIVO

Hasta la fecha, las buenas intenciones han dominado el arte evolutivo. En general, un algoritmo interactivo -que es el utilizado de forma tradicional en este contexto- funciona del siguiente modo: todas las operaciones del algoritmos son llevadas a cabo de modo estándar salvo la evaluación del fitness. Así, los usuarios se encargan de ir decidiendo la calidad del "producto en evolución". Pero en este proceso, el cansancio del usuario afecta al resultado del proceso, como ya ha sido reconocido con anterioridad [4]. Aunque existen propuestas que tratan de evitar este cansancio utilizando dispositivos no intrusivos que analizan el comportamiento del usuario [3], el problema de quién evalúa la calidad -el usuario en este caso- sigue presente.

Una vez que el algoritmo termina, el resultado obtenido en la última generación sería el *producto* generado. Pero en el arte evolutivo, la *obra de arte* producida, si se pretende que emule en calidad la contraparte humana, debería ser mostrada al público y evaluada de forma similar al resto de obras de arte. En realidad no es esto lo que sucede en la mayoría de los casos; típicamente, los resultados obtenidos mediante algoritmos evolutivos han sido presentados a la comunidad en sus propios foros, que incluye revistas dónde los algoritmos son descritos y congresos especializados, tal como EvoMusart, o más generalistas que acogen cualquier resultado notable en el área. Pero en pocas ocasiones este proceso de exposición y muestra es utilizado para obtener información de lo que el público opina.

Este modo de proceder, es bastante lejano a cómo en realidad el mundo del arte funciona. Examinaremos con detalle los tres puntos destacados anteriormente, y propondremos en cada caso cómo podríamos acercarnos más al circuito artístico internacional, para llegar a que el arte evolutivo pueda ocupar el puesto que merece.

#### IV-A. El Test de Turing para el arte

Como se describía más arriba, la dificultad para medir la calidad estética de las obras, ha llevado a proponer la necesidad de un Test de Turing para el arte: si un jurado humano no puede distinguir una obra generada por un computador de una elaborada por un humano, el trabajo, se diría, supera el Test de Turing.

Hay tres razones para cuestionar la utilidad de un test como el anterior. En primer lugar, la indecidibilidad sobre el origen de una obra -humana o creada por computador- no tiene porqué otorgarle de forma automática un sello de calidad. En el arte tradicional, la importancia del reconocimiento del artista detrás de la obra se debe principalmente a cuestiones históricas, de consideraciones académicas, favor del público, y, por último, del mercado del arte, que más que calidad, lo que evalúa es la cotización del artista firmante [14].

Pero en realidad hay una segunda razón que permite cuestionar el mencionado test tenga sentido: algunas tendencias artísticas nacidas en el siglo XX, generan resultados que fácilmente podrían confundirse con el producto de un programa de ordenador. En música, el serialismo y la atonalidad se basa en procesos con un componente estocásticos, y que aunque son llevados a cabo por personas, son sencillamente emulables por computador (mucho más que la música tonal de tradición clásica occidental, en la que el alto número de reglas que la define implica la construcción de sistemas basados en reglas, o con aprendizaje sobre casos conocidos, de alta complejidad [15]). Igualmente en el arte plástico, el uso de herramientas digitales por parte de los artistas, podría también inducir a error a los jurados, confundiendo arte humano, en este caso, por arte generado evolutivamente.

En resumen, el Test de Turing no parece la herramienta necesaria para calificar la calidad de un resultado generado mediante evolución. Quizá, pudiera ser más reveladora la apreciación de especialistas con criterio artístico, como los curadores. No obstante, más allá de la capacidad técnica para emular la manera de hacer una obra, está la capacidad para elaborar un lenguaje diferenciado y reconocible, así como el discurso de trasfondo que subyace en la obra y su relación con factores relacionados con las tendencias y oportunidades de interés particular en cada momento histórico.



#### IV-B. Sobre los artistas.

En los ejemplos más conocidos de arte evolutivo, tal como el que pueda producirse con herramientas similares a Picbreeder, mediante un proceso que podríamos llamar *crowd-painting*, se invita a usuarios particulares, distribuidos a través de internet, para que de modo colectivo evolucionen imágenes. ¿Es éste el procedimiento adecuado para generar un producto artístico de calidad? Creemos que no. Si queremos que el producto final sea de calidad, es necesario incluir en el algoritmo los elementos necesarios - aunque puede que no suficientes- para conseguirlo. En nuestra opinión, esto requiere la presencia de artistas humanos, de modo que sean artistas experimentados los que puedan hacer la evaluación estética de los resultados parciales, y que de este modo el algoritmo pueda progresar, dado que hasta el momento no se ha encontrado la forma de evaluar automáticamente la calidad estética. No basta incluir usuarios en la interacción, deben ser usuarios especiales, artistas, los encargados de la evaluación de la calidad en el proceso evolutivo. Sólo cuando en el futuro los procesos de aprendizaje máquina consigan modelar a los artistas adecuadamente, podrán ser sustituidos, pero mientras tanto los artistas deben estar en el centro del proceso de evaluación.

En algunas de nuestras experiencias recientes, optamos por esta línea de trabajo [16]. No obstante, aunque creemos necesaria la presencia de artistas en el algoritmo evolutivo, esto no tiene por qué ser suficiente. Para certificar la calidad de un trabajo, debe haber una evaluación final que permita discernir sobre la calidad del algoritmo ejecutado, del mismo modo que después de la ejecución de un algoritmo evolutivo estándar, se evalúa la calidad final para saber si la solución obtenida es factible o, en caso contrario, ejecutar de nuevo el algoritmo para intentar de nuevo obtener una solución válida.

En el mundo del arte tradicional, son las competiciones, museos y galerías quienes aplican el filtro final, además, por supuesto, del público que es quién visita las exposiciones y, finalmente, adquiere las obras.

En el dominio de los algoritmos evolutivos, algunos congresos de relevancia, han organizado en ocasiones competiciones internacionales. Cabe destacar el Gecco Evolutionary Art, Design and Creativity competition [7], que ha permitido a los artistas evolutivos enviar sus trabajos para que un jurado internacional eligiera el ganador de la competición.

Este tipo de competiciones, permiten avanzar en alguno de los puntos controvertidos destacados en la sección previa: el establecimiento de un jurado y una competición permite que sea un grupo especializado el que dictamine. En esta línea, podemos referirnos a alguno de nuestros trabajos previos en este dominio, como XY que fue enviado a la competición en el año 2013 y resultó ganador (ver figura 1) [7]. Hay que destacar que aunque el trabajo se apartaba del modelo interactivo tradicional de algoritmo evolutivo, y en su lugar utilizaba la propuesta cococida como Algoritmo Evolutivo Desconectado [17], el resultado fue favorablemente evaluado por el jurado.



Figura 1. XY: ACM Gecco 2013 Evolutionary Art, Design and Creativity competition winner. Four out of the sixty works produced are displayed.

No obstante, la competición se desarrolla en un congreso específico de algoritmos evolutivos, ACM GECCO 2013 en este caso, y el jurado está compuesto por investigadores del área, algunos de ellos siendo también artistas. Pero por lo anterior, tanto el ámbito de la competición como el tipo de jueces, hace que exista una "desviación o tendencia" que favorece el tipo de trabajos presentados.

Entendemos que es necesario dar un paso más para conseguir posicionar el arte evolutivo dónde le corresponde.

#### IV-C. Sobre los jurados.

La composición del jurado es crucial para calificar la calidad de un trabajo. En el mundo del arte, los curadores (comisarios, - curator en inglés) de las exposiciones son los que deciden los artistas cuyo trabajo merecen la pena. Por otro lado, en las competiciones artísticas, la selección de un jurado adecuado es lo que otorga calidad a la misma. Tanto competiciones como exposiciones se llevan a cabo en museos y galerías, que actuando como *crítica* permiten filtrar y definir en cada momento histórico lo que merece la pena del panorama artístico.

Por todo lo dicho anteriormente, entendemos que la forma más adecuada de evaluación del arte evolutivo,

es que compita con el arte humano en igualdad de condiciones en el contexto concreto del arte tradicional: competiciones de arte, galerías y museos.

Describimos a continuación la experiencia obtenida con las obras que hemos desarrollado en los últimos cinco años, y que nos ha permitido afrontar el proceso de selección de calidad descrito anteriormente, en un recorrido por ciudades y galerías de todo el mundo. En las experiencias que describimos, se incluyen tanto galerías de arte, como otras competiciones internacionales alejadas del círculo de los algoritmos evolutivos.

## V. EXPERIMENTOS Y RESULTADOS

Desde el año 2012, utilizando el Algoritmo Evolutivo Desconectado -que avanza en la dirección del algoritmo evolutivo interactivo, permitiendo al usuario ejecutar todos y cada uno de los pasos del algoritmo evolutivo [16]- hemos ido recorriendo una serie de etapas que nos han permitido mejorar los procesos de evaluación de los resultados artísticos, avanzando en el camino que creemos es más adecuado para posicionar el Arte Evolutivo en el mundo del arte plástico, llegando a obtener algunos de los objetivos perseguidos y, como se verá más adelante, tan sólo pendiente de la decisión sobre la ubicación definitiva de las obras generadas, ya sea en alguna colección particular o en algún museo de arte contemporáneo. Tal como se describe anteriormente en la metodología, hemos tratado de afrontar procesos de evaluación de calidad cada vez más cerca del mundo del arte, y más lejos del área de los algoritmos evolutivos.

### V-A. Galerías de Arte y su público

Han sido tres las obras colectivas de arte evolutivo que hemos producido en estos últimos cinco años: *XY*, *XYZ* y finalmente *The horizon project* [5]. Desde el principio se consideró la necesidad de exponer las obras y obtener realimentación de la opinión del público.

En cuanto a la primera obra, *XY*, se decidió mostrarla en congresos del área. Las exposiciones en Cancún, Madrid y Mérida, en congresos como IEEE CEC o MAEB, permitieron obtener información de público *afín*, y detectamos los problemas asociados con la utilización de encuestas a los usuarios, que implican un cansancio similar al de los usuarios que participan de modo interactivo con los algoritmos evolutivos.

Este mismo problema, que se ha repetido con las obras posteriores, está ya siendo objeto de mejora. Recientemente hemos trabajado en un modelo de exposición interactiva, que permite analizar al usuario en la visita, mediante dispositivos Kinect. Los resultados muestran que los datos obtenidos son similares a los obtenidos mediante encuesta, con la ventaja de ser métodos no intrusivos [3]. No obstante, lo que más importa en la propuesta que hacemos, es el modo de evaluación por los actores fundamentales del mundo del arte.

En una segunda etapa, y considerando que el lugar natural para un artista y su obra es una galería de arte, decidimos apostar por este ámbito expositivo. Así, en 2015 y 2017, organizamos exposiciones temporales de la obra *XYZ* en la Galería de Arte "Back Gallery Project", en Vancouver. Conseguimos gestionar la exposición e inauguración del evento en la galería la misma semana que tuvo lugar el congreso IEEE CEC en la ciudad. En el congreso se mostraron algunas reproducciones de la obra, y se redirigió a los asistentes a la galería para la visita. Hay que enfatizar el hecho de que no había ninguna conexión previa entre la galería de arte, dedicada exclusivamente al mundo del arte, y el congreso mencionado.

De forma parecida, se gestionó otra exposición en la Gallerie Louchard de París, en Octubre de 2017, aunque en este caso, la galería si ofrecía a los organizadores del congreso Artificial Evolution 2017 un espacio en el que mostrar arte evolutivo enviado al congreso.

Lo anterior muestra que las galerías de arte pueden estar interesadas en el arte evolutivo igual que en cualquier otro tipo de arte contemporáneo, y que la aceptación de la obra para ser expuesta por parte de galerías de arte, como en los ejemplos descritos anteriormente, son un indicativo, y por tanto un modo de evaluación, de la calidad de las obras.

### V-B. Evaluación definitiva: Competición Internacional de Arte

No obstante, y tal como indicábamos en secciones previas, la mejor manera de evaluar un trabajo artístico, independientemente del procedimiento con que se ha generado, es presentarlo en alguna competición puramente artística, a nivel internacional. Esto es lo que se hizo con la tercera obra, *The Horizon Project* [5] (ver figura 2). Se decidió presentarlo a la competición *Show Your World 2017*<sup>1</sup>, celebrada en

<sup>1</sup><http://www.reartiste.com/juried-exhibition-show-your-world-2017/>



New York, y cuyas obras finalistas serían expuestas en la galería *Gallery MC*, en Manhattan. La obra fue seleccionada por un jurado internacional como obra finalista, siendo la única obra Española finalista en esta competición, y por supuesto la única generada mediante procesos evolutivos.

Hasta dónde sabemos, esta es la primera vez que una obra de estas características es evaluada y seleccionada como finalista en una competición internacional abierta en el ámbito del mundo del arte, con un jurado especialista, y expuesto en una exposición dirigida por un curador profesional.

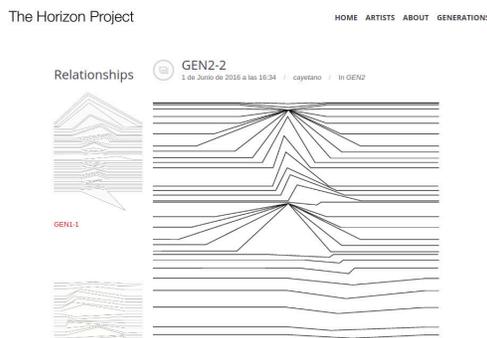


Figura 2. The Horizon Project, available at: <http://merida.herokuapp.com/>

En resumen, aunque en los problemas de optimización la calidad del resultado es fácil de evaluar considerando si el resultado obtenido da solución al problema planteado, creemos que el camino mostrado para evaluar el arte evolutivo en este trabajo, que incluye al público y la crítica, representada por galerías de arte y competiciones internacionales, es el único que puede otorgar un sello de calidad a un resultado artístico.

## VI. CONCLUSIONES

Este artículo presenta nuestra posición sobre lo que consideramos más adecuado para la correcta evaluación de un proyecto de arte evolutivo.

Nuestra propuesta, que renuncia al test de turing por su incapacidad para otorgar un sello de calidad a un trabajo, se basa en involucrar a actores fundamentales del mundo del arte: la crítica y al público.

El artículo muestra como ejemplo el recorrido de un proyecto artístico colectivo que comenzó en 2012, y su proyección en los diferentes foros artísticos, ha permitido dotar de sentido diferenciado a la obra, más allá de la distinción por ser arte evolutivo.

## AGRADECIMIENTOS

Agradecemos el apoyo del Ministerio de Economía y Competitividad proyecto TIN2017-85727-C4-{2,4}-P, Junta de Extremadura, Consejería de Comercio y Economía, proyecto IB16035 a través del Fondo Europeo de Desarrollo Regional, “Una manera de hacer Europa”.

## REFERENCIAS

- [1] Boden, M.A.: The turing test and artistic creativity. *Kybernetes* **39**(3), 409–413 (2010)
- [2] Botstein, L.: Schoenberg and the audience: modernism, music, and politics in the twentieth century. *Schoenberg and his World* pp. 19–54 (1999)
- [3] Fernández, F., García, M., Merelo, J., Aguilar, G., Cruz, C., Hernández, P.: Analyzing evolutionary art audience interaction by means of a kinect based non-intrusive method. In: *Studies in Computational Intelligence series*, vol. 785, pp. 321–347 (2018)
- [4] Frade, M., Fernández de Vega, F., Cotta, C.: Evolution of artificial terrains for video games based on accessibility. In: *European Conference on the Applications of Evolutionary Computation*, pp. 90–99. Springer (2010)
- [5] Hernández, P., Fernández de Vega, F., Cruz, C., Albarrán, V., García, M., Navarro, L., Gallego, T., García, I.: The horizon project: Emotion in lines. *Journal Art and Science* **1**(1), 1–9 (2017)
- [6] House, J.: *Impressionism: Paint and Politics*. Yale University Press (2004)
- [7] Loiacono, D.: Gecco-2013 competitions. *ACM SIGEVOlution* **6**(2), 27–28 (2014)
- [8] McCormack, J.: Open problems in evolutionary music and art. In: *Workshops on Applications of Evolutionary Computation*, pp. 428–436. Springer (2005)
- [9] Peress, M.: *Dvorak to Duke Ellington: A Conductor Explores America’s Music and Its African American Roots*. Oxford University Press on Demand (2004)
- [10] Reichardt, J.: *Cybernetic serendipity: the computer and the arts*. Praeger (1969)
- [11] Romero, J.J.: *The art of artificial evolution: A handbook on evolutionary art and music*. Springer Science & Business Media (2008)
- [12] Secretan, J., Beato, N., D Ambrosio, D.B., Rodriguez, A., Campbell, A., Stanley, K.O.: Picbreeder: evolving pictures collaboratively online. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 1759–1768. ACM (2008)
- [13] Takagi, H.: Interactive evolutionary computation: Fusion of the capabilities of ec optimization and human evaluation. *Proceedings of the IEEE* **89**(9), 1275–1296 (2001)
- [14] Thompson, D.: *The \$12 million stuffed shark: The curious economics of contemporary art*. Macmillan (2010)
- [15] Fernández de Vega, F.: Revisiting the 4-part harmonization problem with gas: A critical review and proposals for improving. In: *Evolutionary Computation (CEC), 2017 IEEE Congress on*, pp. 1271–1278. IEEE (2017)
- [16] Fernández de Vega, F., Cruz, C., Navarro, L., Hernández, P., Gallego, T., Espada, L.: Unplugging evolutionary algorithms: an experiment on human-algorithmic creativity. *Genetic Programming and Evolvable Machines* **15**(4), 379–402 (2014)
- [17] Fernández de Vega, F., Navarro, L., Cruz, C., Chavez, F., Espada, L., Hernandez, P., Gallego, T.: Unplugging evolutionary algorithms: on the sources of novelty and creativity. In: *Evolutionary Computation (CEC), 2013 IEEE Congress on*, pp. 2856–2863. IEEE (2013)

# An Evolutionary Approach to Metroidvania Videogame Design

Álvaro Gutiérrez Rodríguez, Carlos Cotta, Antonio J. Fernández Leiva  
ETSI Informática, Campus de Teatinos, Universidad de Málaga, 29071 Málaga – Spain  
Email: {alvarogr,ccottap,afdez}@lcc.uma.es

**Abstract**—Game design is a fundamental and critical part of the videogame development process, demanding a high cost in terms of time and effort from the team of designers. The availability of tools for assisting in this task is therefore of the foremost interest. These can not just speed up the process and reduce costs, but also improve the overall quality of the results by providing useful suggestions and hints. A conceptual system to approach the construction of this kind of tools is presented in this work. By using a learning component, the preferences and expertise of the designers can be modelled and to some extent simulated. This model is subsequently exploited by an optimization component that tries to create adequate game designs. A proof of concept of the system is provided in the context of level design in Metroidvania games. It is shown that the system can produce quality solutions and hints to the designer.

## I. INTRODUCTION

The development of a videogame encompasses different stages/phases and usually involves teams specialized on particular areas. Among all these phases, the design phase is crucial for the ultimate fate of the game: it is in this stage where it is decided how the game will be, what the requirements for subsequent development phases will be, and most importantly, which the source of fun in the game will be.

Unlike other development stages, design is not so commonly assisted by AI tools. This contrasts with the pervasive use of such tools in content generation. For example, Non-Player Characters (NPCs) are agents controlled by the computer whose behaviour must be believable (i.e., in accordance with the role of that character) to keep the player's immersion in the game. Developers also use procedural generation techniques to generate new content (e.g., maps<sup>1</sup>, weapons<sup>2</sup>, stories<sup>3</sup>, etc.) during gameplay in order to diminish monotony. The use of content generation tools reduces the workload of designers and artists, and produce results that are generally well-received by the end users.

As anticipated before, the field of intelligent tools for game design is still nascent, but it does not mean that it has not yet been explored [1]–[6]. Indeed, previous works provide interesting and explanatory results, paving the way for further developments. While some of them focus on specific videogame genres and in established mechanics, a broader perspective is possible. In this sense, this work is

directed to propose a tool aimed to create a complete game (leaving art and sound aside) for any genre, creating the mechanics, game rules, game elements, NPC behaviors and levels. For this, we propose the use of bioinspired algorithms for learning and optimization. More precisely, we pose the use of evolutionary algorithms to generate game contents (game rules, mechanics, etc.) and machine learning tools such as artificial neural networks to mimic the way the designer thinks. After briefly outlining others related works in Section II, this system is described for a general point of view in Section III. As an initial proof of concept, we have picked the case of Metroidvania games [7]. The deployment of the system on this context is then detailed in Section IV, and the results of an empirical examination are provided in Section V. We close this work with a summary of findings and an outline of future work in Section VI.

## II. BACKGROUND

AI-assisted game design refers to the development of AI-powered tools supporting the game design and development process [6]. Combining these tools with Procedural Content Generation techniques (PCG) is a good approach to aid the game designer.

Liapis *et al.* [4], [8] generate new designs using genetic algorithms (GAs) as a PCG technique. Designers have a map design on which they are working, and the application derives new designs using this former as a seed. The GA uses different criteria to evolve solutions, such as game pace and player balance (see also [9]). The playability of the design is defined by considering if all resources and bases are reachable from any other base or resource. The application shows twelve derivations, six made with the evolution system commented and other six with novelty search. An important part of the experiments involved having professional designers use the tool. The feedback was positive, indicating the system was capable of providing interesting suggestions.

ANGELINA is a cooperative coevolutionary system for automating the process of videogame design. There have been several different versions of ANGELINA in the past [10]–[12]. Focusing on the last version [5], it can create every content of a game: mechanics, game rules, programming, sound, art and levels. The creation of a game starts with a semantic derivation of a sentence or word; after this derivation, free contents (e.g., models, textures, sounds, etc) in agreement with the derivation are searched in the web. Later, mechanics, game

<sup>1</sup><http://spelunkyworld.com/index.html>

<sup>2</sup><https://borderlandsthegame.com/>

<sup>3</sup><https://www.shadowofwar.com/es/>



rules and, finally, levels in agreement with those mechanics and game rules are created. During the process, a game is represented as a map which defines passable and non-passable areas in a two-dimensional grid, a layout which describes the arrangement of player and non-player characters in the map, and a ruleset which describes the effects of collisions between game entities, as well as movement types for the NPCs, and time and score limits for the game [12]. A collection of EAs run concurrently, each of them aimed to optimize a different component; in order to have a complete vision and optimize their individual objectives, they share information on the game (board state, rules, mechanics) during the evolutionary process and use the fitness of individual components to increase the overall fitness of the finished artifact<sup>4</sup>.

### III. AN AUTOMATED SYSTEM FOR GAME DESIGN

The design process is difficult due to the different abstract facets it encompasses. Consider for example the design process of a character: the designer receives the story of the character and some features of their personality (e.g., heroic, brave, etc.); then, the designer creates several different designs, all of which can be functional, well drawn, and using an appropriate color palette. But which of them is the best design? The designer could arrange all different designs in a screenshot of the movie or videogame to see which one fits better but how is this decision taken? Designers need to use their experience and creativity to choose the fittest design.

If we now think about level design in a Metroidvania videogame, the main issue is the same: designers know what kind of experience they want to create with certain mechanics, game rules and level elements specified but, what is the best combination and order of all the elements? Some designs could be created, tested and then the most convincing design (according to the designer's creative mind and subjective opinion) could be refined.

The examples above tackle different elements of a game but they are solved in the same way: through the designer's expertise. In both cases the different designs are evaluated by the mind of the designer, so we need to recreate this cognitive process. To this end, we propose a framework that orchestrates the use of bioinspired algorithms for learning and optimization – see Fig. 1. A typical configuration would involve the use of artificial neural networks (ANNs) for learning and evolutionary algorithms (EAs) for optimization.

Within this framework, EAs will be used to recreate the different ideas that a designer can have during the design process. This is done by trying to optimize an objective function that mimics the designer's goals and preferences. This function is provided by the learning component of the framework. This component is initially seeded with a collection of learning cases, namely examples that can be either positive (goals, appealing features of solutions, etc.) or negative (undesirable features of solutions, traps to be avoided, etc.). Using these, a first model of the designer is built and used by the EA to generate potentially admissible solutions.

<sup>4</sup>Two games produced by this system were presented in the Ludumdare 28 GameJam – <http://ldjam.com/>.

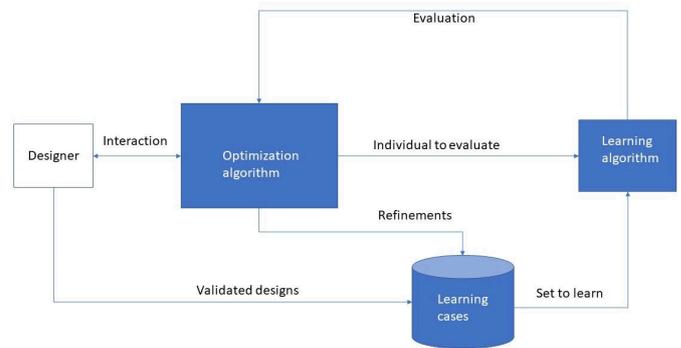


Figure 1: System scheme

During the process, the designer can interact with the system by providing additional examples or clues to refine the model and hence bias the search process in specific directions.

In line with the work by Sorenson and Pasquier [13], in which the fitness function calculate the feasibility and fun of the design, we aim to customize this function to each designer. To this end, the learning component needs to learn to think like the designer and will validate the different individuals (ideas) of the EA like the designer would. A system such as this one can be used to create a complete game of any genre. As an initial step, in this work we have focused on Metroidvania games, whose complexity is more amenable for a study under controlled conditions. This is detailed in next section.

### IV. A CASE STUDY: METROIDVANIA GAME DESIGN

When a game designer starts the design of a new game, one of the starting points is selecting the genre of the game. Each genre has several predefined mechanics that define it. When the designer select the genre, new mechanics are created and mixed. In our case, we focus on the Metroidvania genre [14] due to its diversity of mechanics. This genre is famous for mixing the Metroid and Castlevania games series. Games in this genre feature a large interconnected map through which the player can move, having to obtain objects, weapons or abilities to unlock the different locked areas. The map is composed of different areas, each of which is in turn composed of different rooms (including secret rooms). Rooms are where the different enemies, objects, new abilities, are placed.

Typically, a Metroidvania game is a side-scrolling platform game whose creation can be accomplished by adequately defining the following elements [7]:

- **Mechanics:** all actions that the player or character can do, changing the state of the game as a consequence.
- **Game rules:** these indicate the results of an action, i.e., how an action has modified the state of the game. Rules are composed by a set of previous states of game elements, a set of actions and a set of new states (not necessarily the states of the elements involved in the action). For example:  $\text{stateOf}(\text{boxA}) + \text{action}(\text{moveBoxAToPositionX}) = \text{stateOf}(\text{doorA}, \text{open})$ .
- **Level elements:** all objects included in a certain level (phase, stage, or screen) of the game. We distinguish

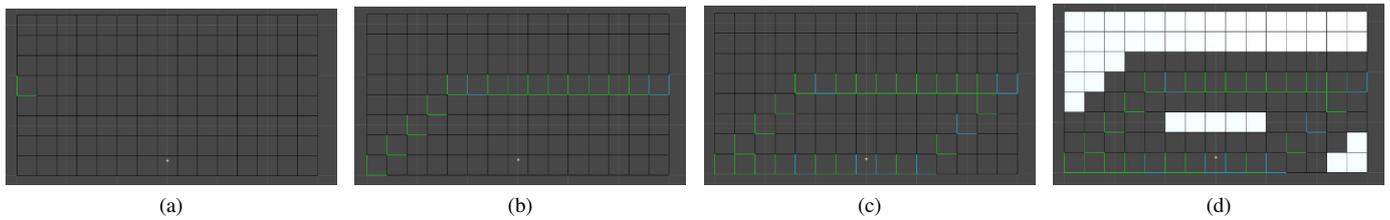


Figure 2: (a) Space partition (b) Main path of the level (c) Joining the main path and the secondary one (d) Complete design of the level.

between two types: interactive and non-interactive. Interactive elements are those whose state can be changed by an action. Conversely, non-interactive elements are those whose state is not affected by player’s actions.

- **Objects:** every game object that the player collect, changing the player’s state as a result. Such a modification will be defined by the game rules, and can be a new ability or updated stats, just to give two examples.
- **Characters:** these are agents controlled by the computer whose goals are defined by the game rules and whose behaviors are defined by game mechanics.
- **Levels:** This is the scenario in which players use their mechanics and the different enemies, objects and level elements created for the game are placed. The game can have one or several levels but the goal in all of them is defined by the game rules.

We are specifically going to focus on the generation of levels. To do so, for each level to be created we pick a width and height, and generate an empty space of these dimensions, discretized into cells whose size doubles the player’s size. Each cell is a possible point of the path to complete the level. Once we have this grid of cells, the designer (or the automated system) creates the path and the optimization algorithm finds a combination of mechanics to use in the so-defined path. The cells that are not part of the path are merely “atrezzo” of the level (e.g., solid walls, pipings, skeletons, etc.). See Fig. 2 for an example of a level created by the system.

The path was calculated by choosing two random points on the left and right sides of the grid and connecting them. Subsequently, a secondary path is created using the same procedure, picking two randoms points in the grid at Manhattan distance  $\geq 2$  of the main path.

### A. Learning process

As stated in the previous section, the learning component is responsible of modelling and simulating the cognitive process of the designer regarding how good a particular level design is. In this work, we have opted for using a neural network for this purpose, although arguably other machine learning methods could be used as well. The role of this component is to serve as a judge capable of assessing the creations of the optimization component in the same way that the designer would do. To this end, we need a reference set composed of good and bad solutions, as dictated by the preferences/knowledge of the designer. We shall use in the following the notation  $Ref_{good}$  and  $Ref_{bad}$  to refer to the collection of good and bad solutions

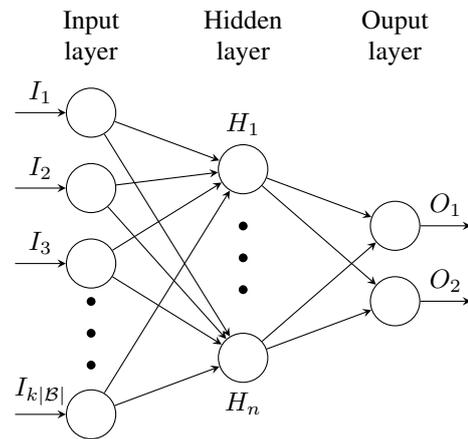


Figure 3: ANN structure used to evaluate motifs

respectively. This is the initial input to the system, and will be used to get the ball rolling in the automated design process.

In order to model the designer’s preferences, the next step is extracting the necessary information from the reference sets. For this purpose, the solutions (i.e., game designs) contained in these are scanned in order to identify particular motifs, which are subsequently classified as good or bad, depending on their presence in good/bad solutions. Notice that this can lead to contradictory inputs to the classifier, since a given motif can appear in both good or bad solutions. The particular learning algorithm used must therefore be able to discern whether the motif is really a significant indicator of goodness/badness or it is simply an irrelevant piece of information.

In the particular context we are considering in this work, solutions are the description of the main path of the level (the same process can of course be applied to the secondary path). We assume we have a collection  $\mathcal{B}$  of possible building blocks for this path, each of them representing the contents of a certain grid cell (i.e., a corridor, a staircase, a moving platform, etc.). The whole path is therefore a sequence of blocks. Let  $m$  be the length of this sequence. In order to extract motifs, we have opted for a very simple strategy which amounts to identifying contiguous subsequences of a certain length  $k$ . Thus, if we have a solution  $[b_1, b_2, \dots, b_m]$ , we can extract  $m - k + 1$  motifs from it:  $\langle b_1, \dots, b_k \rangle$ ,  $\langle b_2, \dots, b_{k+1} \rangle$ , up to  $\langle b_{m-k+1}, \dots, b_m \rangle$ . This is repeated for each solution in either reference set, and each motif is assigned a label *good/bad* depending on its provenance.



Once the set of motifs is available, it is fed to an artificial neural network such as the one depicted in Fig. 3. The input level has  $k|\mathcal{B}|$  neurons, meaning that each motif is encoded as the concatenation of  $k$  bitstrings, each of them representing a block in the motif. To be precise, each of these bitstrings has as many bits as block types are, and only one bit is set to 1 (the bit corresponding to the block in the corresponding position of the motif). As to the output level, it has two neurons, corresponding to each of two classes considered (*good/bad*). After training the ANN, any given motif can be assessed numerically with a value ranging from  $-1$  to  $1$  by subtracting the output (which is between 0 and 1) of these two output neurons. We use this procedure in order to handle contradictory information, which can be present as stated before.

### B. Optimization process

The optimization process has the role of generating tentative solutions. As stated before, each solution indicates the different mechanics to be used in the main path of the level. We represent them with an integer array of length  $m$ . Each position in the array represents a cell in the main path, and each integer value  $0, \dots, |\mathcal{B}| - 1$  indicates a certain type of block. In order to evaluate a given solution, it is scanned and the motifs it contains are extracted, much like it was described in the previous subsection. Given that we are considering substrings of length  $k$  as motifs, it is convenient to define a function

$$\mathcal{M}^{(k)} : \mathcal{B}^m \rightarrow \mathbb{N}^{|\mathcal{B}|^k} \quad (1)$$

that computes how many times each motif appears in a certain solution (note that each solution contains  $m - k + 1$  motifs, some of them possibly repeated, among  $|\mathcal{B}|^k$  different potential motifs).

Now, we resort to the assessment of the ANN in order to evaluate a particular collection of motifs. More precisely, let  $S$  be a solution (a length- $m$  sequence of blocks). Then,  $\mathcal{M}^{(k)}(S)$  would be an array with the frequency of each motif in  $S$ . We will use the notation  $\mathcal{M}^{(k)}(S)_{i_1 \dots i_k}$  to refer to the element in this frequency array corresponding to motif  $\langle i_1 \dots i_k \rangle$ , i.e., the count number of this specific motif in this solution  $S$ . The quality value  $f(S)$  of this solution would be then:

$$f(S) = \sum_{i_1 \dots i_k \in \{1, \dots, |\mathcal{B}|\}^k} T_{i_1 \dots i_k}^{\text{ANN}} \mathcal{M}^{(k)}(S)_{i_1 \dots i_k} \quad (2)$$

where  $T_{i_1 \dots i_k}^{\text{ANN}}$  is the assessment provided by the ANN for that specific motif  $\langle i_1 \dots i_k \rangle$ . Thus, the objective function would compute the sum of the value attributed by the ANN to each motif (which ranges from 1 for very desirable motifs down to  $-1$  for highly undesirable solutions, with all the range of intermediate values for motifs of more or less uncertain desirability) present in the solution, weighted by the corresponding frequency of the motif.

The search engine used is an elitist genetic algorithm (GA) with binary tournament selection, uniform crossover and random mutation. The objective of the search would be providing designers different suggestions that mimic their preferences,

which could be in turn refined online by tagging particular solutions as good or bad and retraining the ANN.

## V. EXPERIMENTS AND RESULTS

The system described in the previous sections has been put to test in order to obtain a proof of concept of its functioning. The results obtained will be described later on in this section. Previously, let us detail the configuration of the experiments.

### A. Experimental setting

The game design task considered in this work consists of constructing the level of a Metroidvania game using a collection  $\mathcal{B}$  of 7 different blocks. The length of the main path is in this case  $m = 50$ , thus resulting in a search space whose size  $|\mathcal{B}|^m \geq 10^{42}$  makes a brute force exploration be out of question. The motifs considered are substrings of length  $k = 3$ . Hence, the ANN utilized in the learning phase has an input layer of  $k|\mathcal{B}| = 21$  neurons. We have chosen  $n = 63$  neurons in the intermediate layer (that is, thrice the size of the input layer), and have 2 output neurons as described in Section IV-A. All neurons have a sigmoid activation function, and the ANN is trained using backpropagation (learning rate  $\delta = 0.2$ , momentum  $\alpha = 0.33$ ; run until the error is less than 0.1 or a maximum of 100,000 learning epochs is reached). As to the GA utilized in the optimization component has a population size of  $\mu = 50$  individuals, crossover probability  $p_c = 0.9$ , mutation probability  $p_m = 1/m = 0.05$ , and is run for  $\text{maxevals} = 5000$  evaluations (we created different sets of parameters, tested them with the same training set and those mentioned before obtained the best results).

We have considered three test cases to evaluate the behavior of the system. Each of these test cases is constructed by creating an initial payoff table for each of the motifs. Once adequate reference sets  $\text{Ref}_{\text{bad}}$  and  $\text{Ref}_{\text{good}}$  are defined (by providing solutions that aim to maximize or minimize the resulting sum of payoffs according to the initial table), the whole system tries to (i) discover the usefulness of each motif (which is quantitatively unknown to the system, and can only be inferred via the appearance of these motifs in good or bad solutions) and (ii) construct good solutions by combining appropriately these motifs (not straightforward in general, given the fact that all motifs in a solution are in partial overlap with each other).

The first test case is given by a payoff matrix

$$T_{xyz} = \begin{cases} 1 & (x = y) \vee (x = z) \vee (y = z) \\ -1 & \text{otherwise} \end{cases} \quad (3)$$

i.e., motifs with 3 different elements are undesirable, whereas motifs with 2 or 3 identical elements are good. This is an easy test case that can nevertheless provide interesting information in terms of the bias of the optimizer towards particular directions. The second test case is actually a variant of the previous one, and is given by the following payoff table:

$$T_{xyz} = \begin{cases} 0 & x = y = z \\ 1 & x \neq y \neq z \\ 3 & \text{otherwise} \end{cases} \quad (4)$$

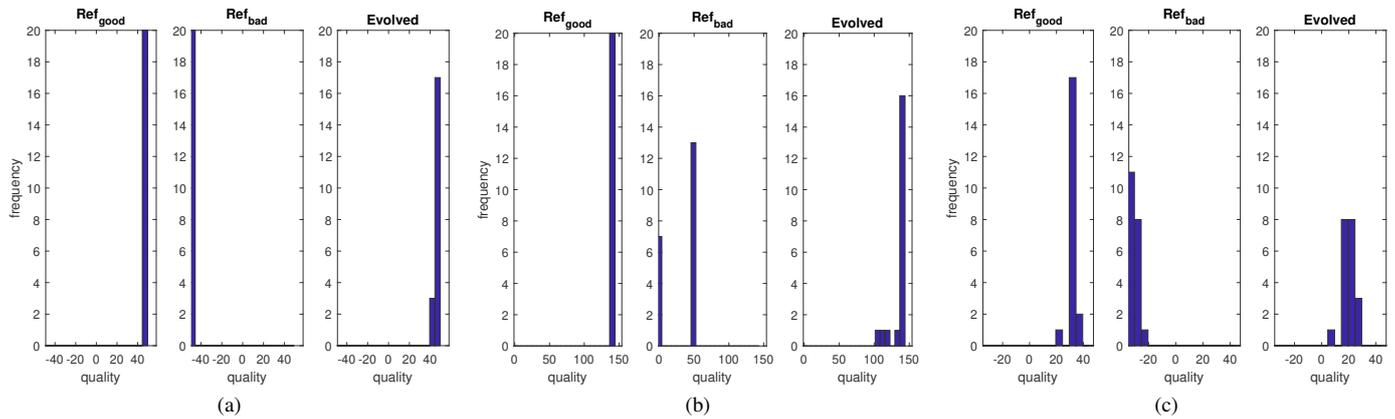


Figure 4: Histogram of objective values according to the underlying payoff table for reference solutions (Ref<sub>good</sub> and Ref<sub>bad</sub>) and solutions evolved by the system. (a) Test case #1 (b) Test case #2 (c) Test case #3

In this case, motifs with 3 identical elements are highly undesirable. motifs with 3 different elements are better, yet suboptimal; the best motifs are those with exactly 2 identical elements. Finally, the third test case is defined via random payoffs:  $T_{xyz}$  is uniformly drawn at random from the interval  $[-1, 1]$  for each particular motif  $\langle x, y, z \rangle$ .

In the first two test cases, perfect reference sets are constructed by picking at random solutions only comprising good or bad motifs (in the second test case, suboptimal motifs are just included in bad solutions). In the third case, we have resorted to an GA analogous to that used in the optimization component aiming to maximize/minimize the objective function defined by the corresponding payoff table. In all cases, both Ref<sub>bad</sub> and Ref<sub>good</sub> comprise 20 solutions each.

For each test case, the ANN has been trained using the motifs extracted from the reference sets and the GA has been run 20 times, keeping the best solution found in each run. All algorithms have been implemented on the videogame engine Unity using C# as programming language. The AForge library<sup>5</sup> has been used to support the ANN.

### B. Results

A first glimpse of the experimental results obtained is provided in Fig. 4. Therein, the objective values of both reference solutions and evolved solutions is shown for each test case. As indicated in previous subsection, the reference solutions for the first two test cases are perfect, in the sense they only contain desirable or undesirable motifs. Thus, the mass of objective values is concentrated on the left end of the histogram for bad solutions and on the right end for good solutions. The reference solutions for the third test case were empirically obtained and hence there is more variety of objective values (note that this may to some extent constitute a more realistic setting, in which solutions provided by the designer are not ideal flawless prototypes but can rather have an inherently noisy structure). In either case, notice how the solutions provided by the EA also tend to cluster towards the right end of the histogram, indicating that they are objectively

Table I: Structural difference between solutions in the test case #1. The number of motifs of each type (based on the number  $b$  of identical blocks in it) is shown for each data set

	b=2	b=3	b=0
Ref <sub>good</sub>	897	63	0
Ref <sub>bad</sub>	0	0	960
Evolved	533	414	13

good according to the hidden criterion used for defining goodness/badness.

Some further insight is obtained if we take a look at the structure of evolved solutions and try to compare these with solutions in either reference set. To this end, we compute for each solution  $S$  the associated motif-frequency array  $\mathcal{M}^{(k)}(S)$ . Subsequently, we can compute the structural distance  $D(S, S')$  between two solutions  $S$  and  $S'$  as the Euclidean distance between the corresponding motif-frequency arrays, i.e.,

$$D(S, S') = \sqrt{\sum_{i_1 \dots i_k} (\mathcal{M}^{(k)}(S)_{i_1 \dots i_k} - \mathcal{M}^{(k)}(S')_{i_1 \dots i_k})^2} \quad (5)$$

Once this is done for each pair of solutions, the resulting distance matrix can be used to perform a hierarchical cluster analysis. We have done this on the solutions available for each test case, using Ward’s minimum variance method to guide the agglomerative clustering process [15]. As can be seen in Fig. 5, in both test cases #2 and #3, evolved solutions have some affinity among them but tend nevertheless to mix with clusters of solutions in Ref<sub>good</sub>. Together with the good objective quality of these solutions discussed before, this indicates that the system did faithfully capture the features of interest in solutions and could combine them appropriately. Test case #1 is also interesting: evolved solutions are objectively good, but they tend to cluster together, mostly apart from solutions in either reference set. If we perform a quick structural analysis, we obtain the results shown in Table I. Note that a few bad motifs (composed of three different blocks;  $b = 0$ ) have slipped into these solutions, although this is not very significant. It is far more interesting to note that evolved solutions tend to have much more motifs composed of identical blocks. This may be an artifact of the learning process, that

<sup>5</sup><http://www.aforge.net.com/>

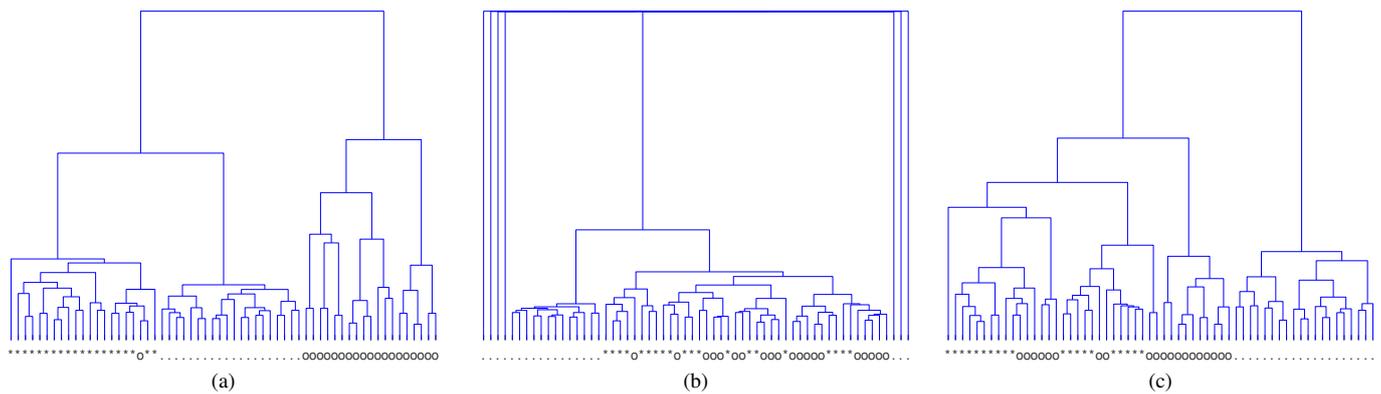


Figure 5: Clustering of solutions in the reference sets and evolved by the system. A dot (‘.’) represents solutions in  $Ref_{bad}$ , a star (‘\*’) solutions in  $Ref_{good}$ , and a circle (‘o’) evolved solutions. (a) Test case #1 (b) Test case #2 (c) Test case #3

might marginally favor some particular motif, or a byproduct of the search dynamics of the EA, whereby it may be easier for it to create good solutions by exploiting this kind of motifs. Of course, at this point the loop could be closed by having the designer inspect these solutions, possibly providing complementary preferences in order to support or discard this kind of solutions.

## VI. CONCLUSIONS AND FUTURE WORK

We have presented the concept of an AI-assisted videogame design system, aimed to help designers create games by suggesting new ideas based on a model of their preferences and knowledge. To this end, we propose the orchestrated use of machine learning techniques and optimization methods, the former to capture the designers’ expertise, and the latter to exploit this expertise in a systematic (and hopefully creative) way. The experimental proof of concept has shown that not only quality solutions analogous to those provided as reference can be generated, but also different non-anticipated biases can appear, providing interesting hints to the designer.

As future work, we plan to deploy the system on a more realistic environment to test its capabilities. Needless to say, closing the loop and having the designer introduce dynamic preferences is another improvement of the foremost interest.

## ACKNOWLEDGMENTS

This work is supported by Spanish Ministerio de Economía, Industria y Competitividad under projects EphemeCH (TIN2014-56494-C4-1-P) and DeepBIO (TIN2017-85727-C4-1-P), and by Universidad de Málaga, Campus de Excelencia Internacional Andalucía Tech.

## REFERENCES

- [1] R. Hunnicke, M. Leblanc, and R. Zubek, “MDA : A formal approach to game design and game research,” in *AAAI Workshop on Challenges in Game AI*, vol. 4. San Jose: Press, 2004, pp. 1–5.
- [2] N. Sorenson and P. Pasquier, “The evolution of fun: Automatic level design through challenge modeling,” in *International Conference on Computational Creativity*, D. Ventura, A. Pease, R. P. y Pérez, G. Ritchie, and T. Veale, Eds. Lisbon, Portugal: Department of Informatics Engineering, University of Coimbra, 2010, pp. 258–267.
- [3] A. Liapis, G. N. Yannakakis, and J. Togelius, “Designer modeling for personalized game content creation tools,” in *The 9th AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment*. Boston, USA: AI Access Foundation, 2013, pp. 11–16.
- [4] —, “Sentient sketchbook: Computer-aided game level authoring,” in *ACM Conference on Foundations of Digital Games*, G. N. Yannakakis, E. Aarseth, K. Jørgensen, and J. C. Lester, Eds. Chania, Crete: Society for the Advancement of the Science of Digital Games, 2013, pp. 213–220.
- [5] M. Cook and S. Colton, “Ludus ex machina: Building a 3d game designer that competes alongside humans,” in *International Conference on Computational Creativity*, S. Colton, D. Ventura, N. Lavrač, and M. Cook, Eds. Ljubljana, Slovenia: computationalcreativity.net, 2014, pp. 54–62.
- [6] G. N. Yannakakis and J. Togelius, “A panorama of artificial and computational intelligence in games,” *IEEE Transactions on Computational Intelligence and AI in Games*, vol. 7, no. 4, pp. 317–335, 2015.
- [7] K. Pearson, “Guide to making metroidvania styled games – part 1,” *PlatformerPower*, 2017, <https://platformerpower.com/post/160130225259/guide-to-making-metroidvania-styled-games-part-1> [accessed 28-Jun-18].
- [8] A. Liapis, G. N. Yannakakis, and J. Togelius, “Designer modeling for sentient sketchbook,” in *2014 IEEE Conference on Computational Intelligence and Games*. Dortmund, Germany: IEEE, 2014, pp. 1–8.
- [9] R. Lara-Cabrera, C. Cotta, and A. J. Fernández-Leiva, “On balance and dynamism in procedural content generation with self-adaptive evolutionary algorithms,” *Natural Computing*, vol. 13, no. 2, pp. 157–168, Jun 2014.
- [10] M. Cook and S. Colton, “Multi-faceted evolution of simple arcade games,” in *2011 IEEE Conference on Computational Intelligence and Games (CIG’11)*, S. Cho, S. M. Lucas, and P. Hingston, Eds. Seoul, South Korea: IEEE, 2011, pp. 289–296.
- [11] M. Cook, S. Colton, and A. Pease, “Aesthetic considerations for automated platformer design,” in *AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment*, M. Riedl and G. Sukthankar, Eds. California, USA: The AAAI Press, 2012, pp. 124–129.
- [12] M. Cook, S. Colton, and J. Gow, “Initial results from co-operative co-evolution for automated platformer design,” in *Applications of Evolutionary Computation – EvoApplications 2012*, ser. Lecture Notes in Computer Science, C. Di Chio *et al.*, Eds., vol. 7248. Berlin, Heidelberg: Springer Verlag, 2012, pp. 194–203.
- [13] N. Sorenson and P. Pasquier, “Towards a generic framework for automated video game level creation,” in *Applications of Evolutionary Computation - EvoApplications 2010*, ser. Lecture Notes in Computer Science, C. Di Chio *et al.*, Eds., vol. 6024. Berlin Heidelberg: Springer Verlag, 2010, pp. 131–140.
- [14] C. Nutt, “The undying allure of the metroidvania,” *Gamasutra*, 2015, [https://www.gamasutra.com/view/news/236410/The\\_undying\\_allure\\_of\\_the\\_Metroidvania.php](https://www.gamasutra.com/view/news/236410/The_undying_allure_of_the_Metroidvania.php) [accessed 29-Jun-18].
- [15] J. H. Ward Jr., “Hierarchical grouping to optimize an objective function,” *Journal of the American Statistical Association*, vol. 58, no. 301, pp. 236–244, 1963.



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

**MAEB 2.1: SESIÓN ESPECIAL:  
SCATTER SEARCH Y  
PATH RELINKING**

**Organizadores:**

ANNA MARTÍNEZ-GAVARA Y

JESÚS SANCHEZ-ORO CALVO







# GRASP with Path Relinking for the Constrained Incremental Graph Drawing Problem

A. Martínez-Gavara

*Dept. Estadística i Inv. Operativa*  
*Universitat de València*  
 València, España  
 gavara@uv.es

A. Napoletano

*Dept. Mathematics and Applications*  
*University of Napoli Federico II*  
 Napoli, Italy  
 antonio.napoletano2@unina.it

P. Festa

*Dept. Mathematics and Applications*  
*University of Napoli Federico II*  
 Napoli, Italy  
 paola.festa@unina.it

T. Pastore

*Dept. Mathematics and Applications*  
*University of Napoli Federico II*  
 Napoli, Italy  
 tommaso.pastore@unina.it

R. Martí

*Dept. Estadística i Inv. Operativa*  
*Universitat de València*  
 València, España  
 rafael.marti@uv.es

**Abstract**—Graph Drawing is a well-established area in Computer Science, with applications from scheduling to software diagrams. The main quality desired for drawings is readability, and edge crossing minimization is a well-recognized method for a good representation of them. This work focuses in incremental graph drawing problems, with the aim to minimize the number of edge crossings while satisfying some constraints to preserve the absolute position of the vertices in previous drawings. We propose a mathematical model and a GRASP (Greedy Randomized Adaptive Search Procedure) with PR (Path Relinking) methodology to solve this problem. Finally, we compare our methodology with CPLEX and heuristic solutions obtained by a well-known black-box solver, LocalSolver.

**Index Terms**—heuristics, graph drawing, path relinking

## I. INTRODUCTION

Graph Drawing is a relevant topic of research in areas such as workflow visualization, database modeling, bioinformatics and decision diagrams. The difficulty lies in getting readable informations from systems represented by graphs. See, for example, Kaufmann and Wagner [4] and Di Battista [1] for a thoroughly survey in graph drawing. The edge-crossing minimization criterion is one of the most common to obtain a readable drawing. The problem of minimizing the number of crossings is NP-complete.

In this work we consider hierarchical graphs, this is not a limitation since there exists several methodologies to convert any directed acyclic graph (DAG) into a layered graph. The Hierarchical Directed Acyclical Graph (HDAG) representation is done by setting all the vertices in layers, and all the edges pointing in the same direction. The most well-known method to obtain a good representation of a graph is the Sugiyama's procedure [9], which has become a standard in the field.

We focus on minimizing the number of edge crossings in incremental graph drawings. The goal is to preserve the mental

map of the user over successive drawings. In this way, we consider a new model adding constraints on both the relative ([7]) and the absolute position of the original vertices ([1] in the context of orthogonal graphs).

In this work, we propose a new mathematical programming formulation and a GRASP (Greedy Randomized Adaptive Search Procedure) with PR (Path Relinking) method. We adapt the well-known Local Solver black-box optimizer to solve this problem. Finally, we compare our heuristic with CPLEX and Local Solver, we have verified that GRASP+PR is able to obtain a fraction of the optimal solutions.

## II. MATHEMATICAL PROGRAMING MODEL

A hierarchical graph  $H = (G, p, L)$  is defined as a graph  $G = (V, E)$  where  $V$  and  $E$  represent the sets of vertices and edges, respectively,  $p$  is the number of layers, and  $L : V \rightarrow \{1, 2, \dots, p\}$  is a function that indicates the layer where a vertex  $v \in V$  resides. Let  $V^t$  be the set of vertices in layer  $t$ , and let  $E^t$  be the set of edges from  $V^t$  to  $V^{t+1}$ , with  $n_t = |V^t|$ .

The problem of minimizing edge-crossing is well-known in graph drawing [1] and, in the context of hierarchical graphs, may be formulated as the problem of finding the optimal ordering in each layer. A drawing  $D$  of a hierarchical graph  $H$  is the pair  $(H, \Pi)$  where  $\Pi$  is the set  $\{\pi^1, \dots, \pi^p\}$ , with  $\pi^t$  establishing the ordering of the vertices in the layer  $t$ . We define as  $C(D)$  the total number of edge crossings in drawing  $D$ .

From an original hierarchical graph  $H = (G, p, L)$  and its drawing  $D = (H, \Pi_0)$ , we can consider the addition of some vertices  $\hat{V}$  and edges  $\hat{E}$  obtaining an incremental graph  $IH = (IV, IE, p, L)$ , where  $IV = V \cup \hat{V}$  and  $IE = E \cup \hat{E}$ ,  $p$  is the number of layers and  $m_t$  is the number of vertices in the incremental graph in layer  $t$ .

This work has been partially supported by the Spanish Ministerio de Economía y Competitividad with grant ref. TIN2015-65460-C02.

The goal in the Incremental Graph Drawing Problem (IGDP) is to minimize the number of edge crossings of an incremental drawing  $ID = (IH, \Pi)$ , while conserving the same relative position between the original vertices as in the original drawing  $D$ . The mathematical programming formulation of IGDP is based on a linear integer formulation for the Multi-Layer Drawing Problem proposed by Jünger et al. in [3], with a new set of constraints that preserves the relative position of the original vertices. As the authors in [3], we define the binary variables  $x_{ik}^t$ , where  $x_{ik}^t$  take the value 1 if vertex  $i$  precedes vertex  $k$  and 0 otherwise, where  $i, k$  are vertices that reside in the same layer  $t$ ,  $t = 1, \dots, p$ . Let  $\pi_0^t(i)$  be the original position of the vertex  $i$ . The new constraints are:

$$\begin{aligned} x_{ij}^t + x_{ji}^t &= 1, & \forall i, j \in V^t : 1 \leq i < j \leq m_t & \quad (1) \\ x_{ij}^t &= 1, & \forall i, j \in V^t : \pi_0^t(i) < \pi_0^t(j). & \quad (2) \end{aligned}$$

Finally, we add the requirement that the positions of the original vertices has to be set close enough to their positions in the original drawing. The maximum distance slack between the original position of a vertex and the new one, is represented by  $K$ . The mathematical model for the Constrained Incremental Graph Drawing Problem (C-IGDP) consists in the IGDP model adding the following set of constraints:

$$\max\{1, \pi_0^t(i) - K\} \leq \pi^t(i) \leq \min\{\pi_0^t(i) + K, m_t\}, \forall i \in V, \quad (3)$$

where  $\pi_0^t(i)$  and  $\pi^t(i)$  represent the position of the vertex  $i$ , original and the new one where  $i$  can be assigned, respectively.

### III. GREEDY RANDOMIZED ADAPTIVE SEARCH PROCEDURE

In this work, we propose a GRASP metaheuristic. The method iteratively performs two phases, constructive and improvement. The first phase employs a greedy function  $g(v)$  that measures the minimum number of edge crossings  $g(v, q)$  when vertex  $v$  is inserted in position  $q$  in its layer, for all positions  $q$ .

Initially, the construction phase starts with the original drawing, and iteratively, a vertex  $v$  is selected from the Restricted Candidate List ( $RCL$ ) and it is placed in the position in which the number of crossings is minimum. The  $RCL$  consists of all unselected vertices ( $CL$ ) with the number of edge crossings lower than or equal to a threshold  $\tau$ :

$$\tau = \min_{v \in CL} g(v) + \alpha \left( \max_{v \in CL} g(v) - \min_{v \in CL} g(v) \right). \quad (4)$$

That is  $RCL = \{v \in CL : g(v) \leq \tau\}$ . The performance of this method depends on the parameter  $\alpha$  which balances greediness and randomness. Note that during the construction phase all the original vertices should maintain the restriction  $\max\{1, \pi_0(v) - K\}$  and  $\min\{\pi_0(v) + K, m_{L(v)}\}$ . The pseudocode of construction phase is described in Fig. 1.

Once a solution  $ID$  is obtained, we apply our improvement method which consists in two neighborhoods  $N_0(ID)$  and  $N_1(ID)$ . First, the method explores  $N_0(ID)$ , which consists

---

```

1  $ID \leftarrow D$ ;
2  $CL \leftarrow IV \setminus V$ ;
3 forall  $v \in CL$  do
4   | compute  $g(v)$  and  $\tau$ ;
5 forall  $v \in CL$  do
6   | if  $g(v) \leq \tau$  then
7     | |  $RCL \leftarrow RCL \cup \{v\}$ ;
8 while  $ID$  is not complete do
9   |  $v^* \leftarrow \text{select\_node\_randomly}(RCL)$ ;
10  |  $ID \leftarrow \text{add\_node\_to\_solution}(v^*)$ ;
11  | recompute  $g$  and  $\tau$ ;
12  | rebuild  $RCL$ ;
13 return  $ID$ 

```

---

Fig. 1. Constructive phase for the C-IGDP.

in swapping the positions of two incremental vertices. For a incremental vertex  $v$ , from the first until the last incremental vertex in a layer, our procedure searches the best swap move with all the other incremental vertices, and performs it if it reduces the number of edge crossings. The algorithm scans all the swap moves from layer 1 to  $p$  until no further improvement is possible. Since only incremental vertices are involved, all the moves are feasible. Henceforth, we call this local search phase as *Swap*.

Then, the local search method resorts to a second phase, called *Insertion*, based on neighborhood  $N_1(ID)$ . In a given layer, the method scans all incremental vertices (starting from the first one) and explores all its feasible insertions in previous positions (a move is feasible if the position of the original vertices is within the limits of (3)). As in the case of  $N_0(ID)$ , the local search performs sweeps from layer 1 to  $p$  until no improvement is possible.

Our improvement procedure ends when *Swap* and *Insertion* phases are performed and a local optimum is found.

### IV. PATH RELINKING

In this work, we propose a hybridization of GRASP with forward Path Relinking (PR). PR was originally proposed in the context of Tabu Search [2] to integrate search diversification and intensification. Later, Laguna and Martí in [6] adapted this technique as an intensification phase for GRASP. The method generates intermediate solutions in the path to connect high-quality solutions, which could be better or more diverse than the solutions being connected.

Let  $ID^i$  and  $ID^g$  be the initial and guiding incremental drawings, respectively. A path relinking move consists of replacing an entire layer from the initial solution  $ID^i$  with a layer from  $ID^g$ . Fig. 2 illustrates the path between two solutions  $ID^i$  and  $ID^g$  with 3 layers and 6 vertices. The three first intermediate solutions  $ID^1$ ,  $ID^2$  and  $ID^3$  are generated from  $ID^i$ , exchanging one of its layer with the layers of  $ID^g$ . The process continues from the best solution found, in this case solution  $ID^1$  with  $C(ID^1) = 2$ , in case of ties the algorithm choose one of the solutions at random. The algorithm finds two solutions,  $ID^4$  and  $ID^5$ , that are better

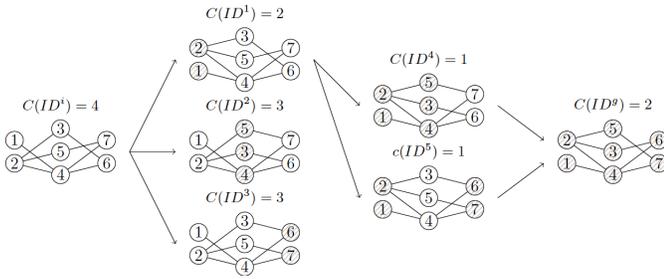


Fig. 2. Illustration of PR.

than  $ID^i$  and  $ID^g$ , both with number of edge crossings equal to 1.

The PR explores the path between all pairs of solutions in a set, called *Elite Set* ( $ES$ ), which is constructed with  $m = |ES|$  solutions generated with our procedure, and has the property of being as good as diverse as possible. Initially, the  $ES$  contains the  $m$  first solutions obtained with our GRASP. In each iteration, this set is updated with the generated solution  $ID^*$  if  $ID^*$  is better than the best solution in  $ES$  or sufficiently different from the other elite solutions. Diversity is measured as the number of positions that are not occupied by the same vertices divided by the number of vertices in the graph (with a distance larger than a parameter  $\gamma$ ), while the quality is evaluated by the objective function. The algorithm ends when no new solutions are admitted to  $ES$ .

## V. EXPERIMENTAL RESULTS

This section describes the experimental analysis to study the effectiveness and efficiency of the procedures presented above. In particular, we consider the following methods: GRASP (construction phase + local search), and GRASP+PR where we couple GRASP with Path Relinking. We also compare our heuristics with the solution obtained by running the integer linear programming proposed above with `LocalSolver`, and `CPLEX`.

The algorithms are implemented in C++, and the experiments have performed in an Intel Corei7-4020HQ CPU @2.60Ghz x 8. The set of instances consists of 240 files with 2, 6, 13 and 20 as the number of layers and the graph density varying in the range  $\{0.065, 0.175, 0.3\}$ . This set is generated in line with previous graph drawing papers [8] and [5], and it is available on-line in the web-page <http://www.opticom.es>.

To avoid over-training, we consider 24 representative instances from the set of 240 to fine tune the algorithmic parameters. Note that, an important element is the value of the slack,  $K$ , between the original position of the vertices and the feasible ones. In this work, we consider low values of this parameter,  $K = 1, 2$  and  $3$ . Then, for each instance in the testing set, we have at most three different instances, one for each value of  $K$  (if the number of incremental vertices in one layer is less than  $K$ , then this value cannot be considered). To sum up, we have 609 instances in our *testing set*, and 62 instances in the *training set*.

These preliminary experimentation is devoted to fine tune the parameters in our GRASP+PR heuristic. First, the value of the parameter  $\alpha$  in the construction phase which controls the balance between the diversity and the quality of the solution. We test three different values of  $\alpha$ : 0.25, 0.5, and 0.75, and we also include a variant, labelled as *random* that, for each construction, the value of  $\alpha$  is selected by random in the range  $[0, 1]$ . The best performance is achieved with this *random* variant. The last parameters to be set are the elite set size and the distance parameter in the PR procedure. We set these values to  $|ES| = 3$  and  $\gamma = 0.2$ . The selection of the values of the parameters in these preliminary experiments is a trade-off between quality and computing time, for this reason, we do not reproduce the tables.

Table I shows the comparison between GRASP and GRASP+PR with `CPLEX` and `LocalSolver` over the entire set of 609 instances, classified by size. We execute our heuristics for 100 iterations, `LocalSolver` is run with a time limit of 20 seconds on the instances with 2 layers, and 60, 150 and 300 seconds on those with 6, 13 and 20 layers, respectively. Finally, we configure `CPLEX` to run for a maximum of 1800 seconds. This table shows for each procedure, the average number of crossings ( $\bar{C}$ ), the average percent deviation from the best solution found ( $\% dev$ ), the average percentage deviation between the heuristic solution value and the `CPLEX` best solution value ( $\% gap$ ), the number of best solutions ( $Bests$ ), the number of optimum solutions ( $Opt$ ), and the CPU-time in seconds required to execute the method ( $Time$ ).

TABLE I  
COMPARISON ON ENTIRE BENCHMARK SET ACCORDING TO INSTANCE SIZE

Procedures	$\bar{C}$	$\% gap$	$\% dev$	$Bests$	$Opt$	$Time$
2 Layers ( $32 \leq n \leq 96$ ), 171 instances						
<code>CPLEX</code>	2408.50	-	0.00	171	171	0.77
GRASP	2409.19	0.14	0.14	161	161	1.11
GRASP+PR	2408.92	0.14	0.14	164	164	1.18
<code>LocalSolver</code>	2785.47	17.01	17.01	12	12	20.11
6 Layers ( $48 \leq n \leq 288$ ), 159 instances						
<code>CPLEX</code>	9995.70	-	0.01	157	157	56.24
GRASP	9997.43	0.13	0.14	81	81	5.53
GRASP+PR	9994.32	0.08	0.08	100	98	5.39
<code>LocalSolver</code>	11024.89	16.59	16.6	0	0	62.43
13 Layers ( $104 \leq n \leq 611$ ), 141 instances						
<code>CPLEX</code>	23469.05	-	0.21	131	128	273.77
GRASP	23319.41	0.13	0.33	29	27	15.22
GRASP+PR	23305.22	0.02	0.22	54	44	15.34
<code>LocalSolver</code>	25530.24	15.95	16.16	0	0	162.06
20 Layers ( $120 \leq n \leq 960$ ), 138 instances						
<code>CPLEX</code>	37918.20	-	0.38	118	116	383.73
GRASP	37522.42	0.03	0.39	21	20	25.77
GRASP+PR	37495.44	-0.12	0.24	49	29	28.39
<code>LocalSolver</code>	40954.07	14.30	14.68	0	0	328.77

Table I shows that, as expected, GRASP+PR obtains better results than GRASP. It is worth mentioning that `CPLEX` is able to obtain the optimal solution in 572 out of the 609 instances, and, with similar CPU time as our heuristics, it is able to obtain all the exact solutions for the small instances. However, in large instances, our heuristics are able to obtain similar quality

results as CPLEX with lower CPU time. Note that GRASP + PR is able to obtain a % *gap* of  $-0.12$  which means that on average beats CPLEX. LocalSolver obtains the largest deviations in both % *dev* and % *gap*, even if it is executed for longer CPU times than the competing heuristics.

## VI. CONCLUSIONS

In this work, we propose a new mathematical model to tackle the Multilayer Incremental Graph Drawing Problem. We consider new constraints (by means of a parameter  $K$ ) to preserve key characteristics when updating an existing drawing. We develop a GRASP algorithm combined with a Path Relinking to obtain high quality solutions in the long term. We compare our heuristic with general solvers as CPLEX, which is able to obtain optimal solutions in 572 out of the 609 instances, and LocalSolver. GRASP+PR is competitive with them, obtaining similar quality solutions as CPLEX in smaller times on large instances, and outperforming LocalSolver.

## REFERENCES

- [1] G. Di Battista, P. Eades, R. Tamassia, and I. G. Tollis. *Graph Drawing: Algorithms for the Visualization of Graphs*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 1st edition, 1998.
- [2] F. Glover and M. Laguna. *Tabu Search*. Kluwer Academic Publishers, Norwell, MA, USA, 1997.
- [3] M. Jünger, E. K. Lee, P. Mutzel, and T. Odenthal. A polyhedral approach to the multi-layer crossing minimization problem. In *International Symposium on Graph Drawing*, pages 13–24. Springer, 1997.
- [4] M. Kaufmann and D. Wagner, editors. *Drawing Graphs: Methods and Models*. Springer-Verlag, London, UK, UK, 2001.
- [5] M. Laguna, R. Martí and V. Valls. Arc crossing minimization in hierarchical digraphs with tabu search. *Computers and Operations Research*, 24:1175–1186, 1997.
- [6] M. Laguna and R. Martí. Grasp and path relinking for 2-layer straight line crossing minimization. *INFORMS Journal on Computing*, 11:44–52, 1999.
- [7] R. Martí, A. Martínez-Gavara, J. Sánchez-Oro, and A. Duarte. Tabu search for the dynamic bipartite drawing problem. *Computers & Operations Research*, 91:1–12, 2018.
- [8] J. Sánchez-Oro, A. Martínez-Gavara, M. Laguna, A. Duarte, and A. Martí. Variable neighborhood scatter search for the incremental graph drawing problem. *Computational Optimization and Applications*, 68:775–797, 2017.
- [9] K. Sugiyama, S. Tagawa, and M. Toda. Methods for visual understanding of hierarchical system structures. *IEEE Trans. Syst. Man, Cybern.*, 11:109–125, 1981.



# Detección de puntos débiles en redes utilizando GRASP y Path Relinking

Sergio Pérez-Peló

Dept. of Computer Sciences

Universidad Rey Juan Carlos

C/Tulipán, S/N, 28933, Móstoles, Spain

Email: sergio.perez.pelo@urjc.es

Jesús Sánchez-Oro

Dept. of Computer Sciences

Universidad Rey Juan Carlos

C/Tulipán, S/N, 28933, Móstoles, Spain

Email: jesus.sanchezoro@urjc.es

Abraham Duarte

Dept. of Computer Sciences

Universidad Rey Juan Carlos

C/Tulipán, S/N, 28933, Móstoles, Spain

Email: abraham.duarte@urjc.es

**Resumen**—El avance que se ha producido en la tecnología en los últimos años ha hecho que sea imprescindible disponer de herramientas que permitan monitorizar y controlar las debilidades que aparecen en redes. Debido al carácter dinámico de las redes, continuamente se conectan y desaparecen dispositivos de las mismas, siendo necesario reevaluar las debilidades que han aparecido tras cada modificación. La evaluación de estas debilidades tiene como objetivo proporcionar información de utilidad al responsable de la red para conocer qué nodos de la misma es necesario reforzar. Los continuos cambios crean la necesidad de disponer de herramientas que evalúen los puntos críticos en tiempos reducidos. En este trabajo se presenta un algoritmo metaheurístico basado en la metodología GRASP (*Greedy Randomized Adaptive Search Procedure*) para detectar puntos débiles en redes. Además, se propone un método de combinación basado en *Path Relinking* para mejorar la calidad de las soluciones generadas. Los resultados experimentales muestran la calidad de la propuesta comparándola con el mejor algoritmo encontrado en el estado del arte.

**Index Terms**— $\alpha$ -separator problem, GRASP, Path Relinking, nodos críticos

## I. INTRODUCCIÓN

En los últimos años la ciberseguridad se ha convertido en uno de los campos más relevantes para todo tipo de usuarios: desde empresas e instituciones hasta usuarios individuales. El incremento del número de ataques a diferentes redes, así como de la importancia de la privacidad en Internet, han creado la necesidad de tener redes más seguras, confiables y robustas. Un ciberataque a una compañía que conlleve pérdida de información personal de sus clientes puede resultar en un importante daño económico y social [1]. Además, los ataques de Denegación de Servicio (del inglés *Denial of Service*, *DoS*) y ataques de Denegación de Servicio distribuidos (del inglés *Distributed Denial of Service*, *DDoS*) han ido siendo cada vez más comunes, debido a que un ataque exitoso puede resultar en la deshabilitación de un servicio de un proveedor de Internet, por ejemplo. Además, si otros servicios dependen a su vez del servicio atacado, podría producirse un fallo en cascada, afectando a un mayor número de clientes [2].

Es importante identificar cuáles son los nodos más importantes en una red. Ésta es una cuestión de interés para ambas partes de un ciberataque: el atacante y el defensor. El primero estará interesado en deshabilitar dichos nodos con el objetivo de hacer la red más vulnerable, mientras que el

segundo estará interesado en reforzar esos nodos importantes con medidas de seguridad más robustas. Además, ambas partes quieren consumir la mínima cantidad de recursos posibles para minimizar los costes derivados del ataque / defensa: por un lado, el atacante está interesado en ocasionar el máximo daño posible a la red empleando la mínima cantidad de recursos posible; por otro lado, el defensor querrá reforzar la red minimizando los costes de mantenimiento y seguridad. Por lo tanto, es interesante para ambas partes identificar cuáles son los puntos más débiles en la red.

Definimos una red como un grafo  $G = (V, E)$ , donde  $V$  es el conjunto de vértices ( $|V| = n$ ) y  $E$  es el conjunto de aristas ( $|E| = m$ ). Un vértice  $v \in V$  representa un nodo de la red, mientras que una arista  $(v_1, v_2) \in E$ , con  $v_1, v_2 \in V$  indica que hay una conexión en la red entre los vértices  $v_1$  y  $v_2$ . Definimos un separador de una red como un conjunto de vértices  $S \subseteq V$  cuya eliminación supone la separación de la red en dos o más componentes conexas. Formalmente,

$$V \setminus S = C_1 \cup C_2 \dots \cup C_p \\ \forall (u, v) \in E^* \exists C_i : u, v \in C_i$$

donde  $E^* = \{(u, v) \in E : u, v \notin S\}$ .

Este trabajo se centra en encontrar un conjunto de vértices mínimo  $S^*$  que permita separar la red  $G$  en componentes conexas de tamaño menor que  $\alpha \cdot n$ . En términos matemáticos,

$$S^* \leftarrow \arg \min_{S \in \mathcal{S}} |S| \quad : \quad \max_{C_i \in V \setminus S} |C_i| \leq \alpha \cdot n$$

Cabe mencionar que el número de componentes conexas resultantes no es relevante para este problema. La restricción actual del problema del separador  $\alpha$  ( $\alpha$ -SP) es que el número de vértices en cada componente conexa debe ser menor o igual que  $\alpha \cdot n$ . Este problema es  $\mathcal{NP}$ -completo para redes de topología general cuando se consideran  $\alpha \geq \frac{2}{3}$  [3]. Se han propuesto algunos algoritmos en tiempo polinómico cuando la topología de la red es un árbol o un ciclo [4]. Sin embargo, estos algoritmos requieren tener un conocimiento previo de la topología de la red, lo que no es usual en problemas de la vida real.

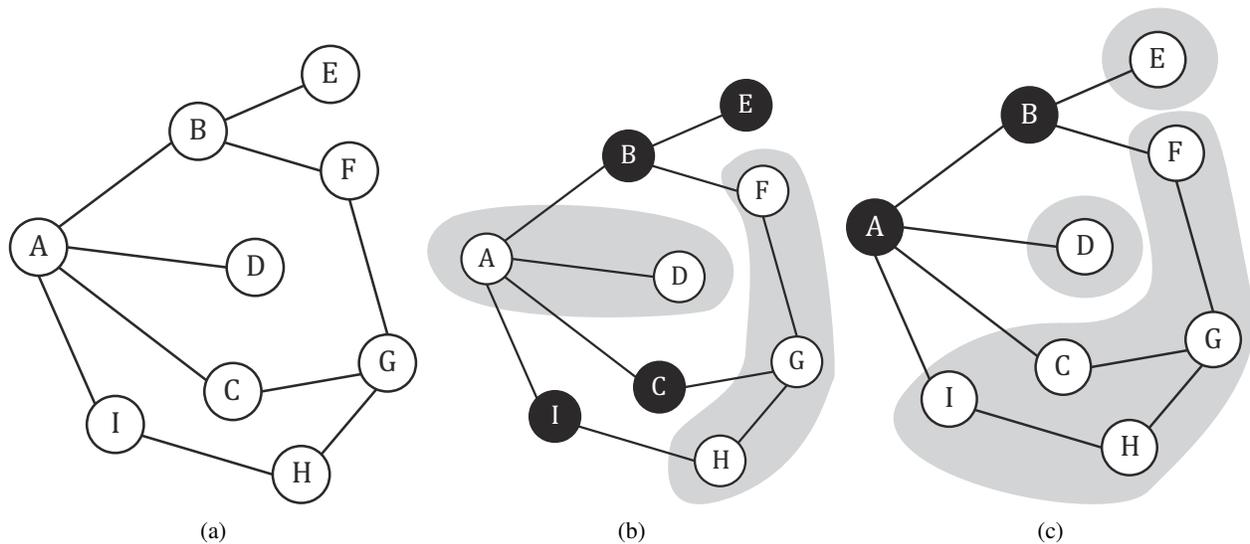


Figura 1: 1(a) Ejemplo de un grafo derivado de una red, 1(b) una solución factible con 4 nodos en el separador (B, C, E, y I), y 1(c) una solución mejor con 2 nodos en el separador (A y B)

Este problema ha sido abordado tanto desde la perspectiva exacta como la heurística. En concreto, se han presentado algoritmos que resuelven el problema en un tiempo polinómico para topologías como árboles o ciclos, así como un algoritmo voraz con una relación de aproximación de  $\alpha \cdot n + 1$  [4]. Adicionalmente, un algoritmo heurístico para estudiar los separadores y los Sistemas Autónomos de Internet se propuso en [5]. Dependiendo del valor de  $\alpha$ , el problema del separador  $\alpha$  puede relacionarse con otros problemas bien conocidos. En particular, cuando  $\alpha = \frac{1}{n}$ , es equivalente al *minimum vertex cover problem*, y cuando  $\alpha = \frac{2}{n}$  es análogo al *minimum dissociation set problem*. Por lo tanto, el problema del separador  $\alpha$  es una generalización de estos problemas, que son también  $\mathcal{NP}$ -completos [6].

## II. PROPUESTA ALGORÍTMICA

*Greedy Randomized Adaptive Search Procedure (GRASP)*, que en castellano se podría traducir como *procedimientos de búsqueda voraz, aleatorizados y adaptativos*, es un procedimiento multi-arranque que fue originalmente propuesto en [7] pero no se definió formalmente hasta [8]. Los procedimientos multi-arranque son un conjunto de procedimientos que intentan evitar quedar atrapados en óptimos locales reiniciando el procedimiento desde otro punto de inicio del espacio de búsqueda, lo que permite aumentar la diversificación de la estrategia de búsqueda. Esta metaheurística se ha utilizado recientemente con éxito en varios problemas de optimización [9]–[11].

Cada iteración en GRASP tiene dos fases bien diferenciadas: construcción y mejora. La primera tiene como objetivo generar una solución inicial de calidad para el problema, mientras que la segunda trata de mejorar la solución inicial a través de algún método de optimización local [12]. Tradicionalmente el optimizador de la segunda fase suele ser

un procedimiento de búsqueda local sencillo, pero es común combinar esta metaheurística con procedimientos de búsqueda más complejos, como pueden ser Tabu Search [13] o Variable Neighborhood Search [14], entre otros, lo que prueba la versatilidad de la metodología GRASP.

### II-A. Criterio voraz

La fase de construcción necesita definir un criterio voraz  $g(v)$  que evalúe, para cada vértice  $v \in V$ , la relevancia de insertar dicho vértice en la solución. Para el problema que estamos tratando,  $\alpha$ -SP, el criterio voraz debe indicar cuáles de los vértices que aún no han sido incluidos en la solución son nodos críticos en la red.

En este trabajo se propone la utilización de criterios utilizados en el área del análisis de redes sociales, de manera que se tratará de identificar qué vértices serían los más importantes de la red si ésta se tratara de una red social. En el análisis de redes sociales, un vértice es importante si mantiene a un gran número de usuarios de la red conectados entre sí [15], por lo que la analogía con el problema del  $\alpha$ -SP es directa: un vértice es importante en la red si su desaparición hace que los dispositivos conectados a él dejen de estar conectados.

Existen numerosas métricas para evaluar la importancia de un usuario en una red social, siendo el cálculo de la mayoría de ellas muy costoso computacionalmente. Esto es debido a que varias de las métricas, como pueden ser *Betweenness* [16] o *PageRank* [17] necesitan conocer todos los caminos más cortos que pasan entre cada par de usuarios de la red. En este trabajo se utilizará la métrica denominada *closeness* [18], la cual considera que un vértice es importante si es alcanzable (i.e., se puede llegar a él a través de muchos caminos) por un elevado número de vértices de la red. Más formalmente, dada una red conexa  $G$ , el valor del *closeness* de un vértice se calcula como la suma de la longitud de las rutas más cortas entre el nodo en cuestión y el resto de nodos en el grafo.



Cabe destacar que la evaluación de esta métrica solo necesita conocer el camino más corto entre cada par de vértices, por lo que basta con realizar un recorrido en anchura (si la red no es ponderada) o aplicar el algoritmo de Dijkstra (si la red es ponderada). La idea que subyace bajo esta métrica es que, cuanto más central es un nodo, más cerca está de todos los demás nodos.

El valor del *closeness* de un nodo  $v \in V$ , definido como  $C(v)$  se evalúa como el cálculo inverso de la suma de las distancias desde ese nodo  $v$  hasta el resto de nodos de la red  $u \in V \setminus \{v\}$ . En términos matemáticos,

$$C(v) \leftarrow \frac{1}{\sum_{u \in V \setminus S} d(v, u)}$$

donde  $d(v, u)$  es la distancia entre los nodos  $v$  y  $u$ . En este trabajo, se considera que la distancia entre dos vértices  $u, v \in V$  será la longitud del camino más corto que conecta  $u$  con  $v$ . Cabe destacar que esta métrica solo tiene sentido en componentes conexas, ya que de otra manera no sería posible encontrar un camino entre los vértices  $u$  y  $v$ .

### II-B. Fase de construcción

El procedimiento de construcción parte de una solución vacía e iterativamente añade vértices a dicha solución hasta que ésta es factible. En el caso del  $\alpha$ -SP, inicialmente ningún vértice ha sido añadido al separador, por lo que es necesario añadir vértices al mismo hasta cumplir la restricción de que la red se encuentra dividida en componentes conexas de tamaño inferior a  $\alpha \cdot n$ . El Algoritmo 1 muestra el pseudocódigo del método de generación de soluciones propuesto.

---

#### Algorithm 1 Construir( $G, \beta$ )

---

```

1:  $v \leftarrow \text{Random}(V)$ 
2:  $S \leftarrow \{v\}$ 
3:  $CL \leftarrow V \setminus \{v\}$ 
4: while not esFactible( $S, G$ ) do
5:    $g_{\min} \leftarrow \min_{v \in CL} C(v)$ 
6:    $g_{\max} \leftarrow \max_{v \in CL} C(v)$ 
7:    $\mu \leftarrow g_{\max} - \beta \cdot (g_{\max} - g_{\min})$ 
8:    $RCL \leftarrow \{v \in CL : C(v) \geq \mu\}$ 
9:    $v \leftarrow \text{Random}(RCL)$ 
10:   $S \leftarrow S \cup \{v\}$ 
11:   $CL \leftarrow CL \setminus \{v\}$ 
12: end while
13: return  $S$ 

```

---

El procedimiento comienza eligiendo al azar el primer vértice que va a ser incluido en la solución (pasos 1-2). La elección aleatoria de este primer elemento permite aumentar la diversidad de las soluciones generadas en la fase de construcción. A continuación, se crea la lista de candidatos  $CL$  con todos los vértices de la red salvo el elegido inicialmente (paso 3). El método de construcción entonces añade un nuevo vértice a la solución hasta que ésta satisfaga las restricciones del problema (pasos 4-12). La función *esFactible* tiene como

objetivo comprobar que todas las componentes conexas de la red tienen un tamaño inferior a  $\alpha \cdot n$  si se eliminan los nodos incluidos en la solución parcial  $S$ .

Tras ello, se calculan el mínimo y el máximo valor (pasos 5 y 6, respectivamente) para la función voraz elegida. En este caso, se utiliza el valor de *closeness* descrito en la Sección II-A. Estos dos valores se utilizan para calcular un umbral  $\mu$  (paso 7) que limitará los vértices que entran a formar parte de la lista de candidatos restringida  $RCL$  (paso 8). El valor del umbral dependerá de un parámetro  $\beta$  (con  $0 \leq \beta \leq 1$ ) que controla la aleatoriedad o voracidad del método. Por un lado, si  $\beta = 0$ , entonces  $\mu = g_{\max}$  y, por tanto, solo se considerarán en la  $RCL$  aquellos vértices con el máximo valor de *closeness*, resultando en un método completamente voraz. Por otra parte, si  $\beta = 1$ , entonces  $\mu = g_{\min}$ , formando parte de la  $RCL$  todos los vértices de la  $CL$ , convirtiéndose así en un método totalmente aleatorio. De esta forma, cuanto mayor sea el valor del parámetro  $\beta$ , más aleatorio será el método, y viceversa. La Sección III discutirá cómo afecta el valor de este parámetro a la calidad de las soluciones obtenidas.

### II-C. Fase de mejora

Las soluciones generadas en la fase de construcción se han construido mediante un procedimiento aleatorizado (a través del parámetro  $\beta$ ), por lo que, en general, es posible aplicar un método de optimización local para mejorar la calidad de la solución. Aunque es posible utilizar cualquier tipo de optimizador en esta fase, el problema tratado requiere de la obtención de soluciones en períodos cortos de tiempo, por lo que se han descartado optimizadores complejos, optando por un procedimiento de búsqueda local tradicional.

Los procedimientos de búsqueda local tienen como objetivo encontrar el óptimo local de una solución con respecto a una vecindad predefinida. En primer lugar, es necesario definir qué vecindad va a explorar el procedimiento. En este trabajo se considerará la vecindad  $2 \times 1$ , la cuál contiene a todas las soluciones alcanzables desde una solución inicial  $S$  mediante la eliminación de dos vértices que estaban originalmente en la solución y la inserción de un nuevo vértice en la misma. Cabe destacar que cualquier movimiento dentro de esta vecindad que produzca una solución factible habrá mejorado el valor de la función objetivo, ya que habrá reducido el conjunto de vértices que necesitan ser eliminados de la red en una unidad. Más formalmente, la vecindad se define como:

$$N(v, S) \leftarrow \{S' : S' \leftarrow S \setminus \{u, v\} \cup \{w\}, \\ \forall u, v \in S \wedge \forall w \in V \setminus S\}$$

Existen dos métodos tradicionales para explorar la vecindad definida: *First Improvement* y *Best Improvement*. El primero recorre todas las soluciones de la vecindad, realizando siempre el primer movimiento que conduzca a una solución de mayor calidad, comenzando la búsqueda de nuevo desde la nueva solución. Sin embargo, *Best Improvement* primero explora todas las soluciones existentes en la vecindad, realizando el movimiento que lleve a la solución de mayor calidad.

En este trabajo se considerará únicamente la variante *First Improvement* debido a dos motivos principales. En primer lugar, *First Improvement* requiere de un menor coste computacional ya que no recorre la vecindad completa para realizar un movimiento y, como se ha mencionado en otras ocasiones, en este problema se requiere un tiempo de cómputo reducido. Por otra parte, dada la vecindad  $2 \times 1$  definida, cualquier movimiento que lleve a una solución factible producirá una solución cuyo valor de la función objetivo se habrá mejorado en una unidad, sea cual sea el movimiento que se realice. Por tanto, para esta vecindad no es útil comprobar todos los posibles movimientos disponibles.

Teniendo en cuenta lo mencionado anteriormente, el procedimiento de búsqueda local propuesto para el problema del  $\alpha$ -SP consiste en recorrer de manera aleatoria la vecindad de cada una de las soluciones generadas en la fase de construcción, parando cuando no se encuentre ninguna solución de mayor calidad en la misma, y devolviendo la mejor solución encontrada en la búsqueda.

#### II-D. Path Relinking

*Path Relinking* (PR) es un método de combinación de soluciones propuesto originalmente como una metodología para integrar estrategias de intensificación y diversificación en el contexto de la búsqueda tabú [19]. El comportamiento de PR se basa en explorar las trayectorias que conectan soluciones de alta calidad, con el objetivo de generar soluciones intermedias que, eventualmente, pueden ser mejores que las soluciones originales utilizadas para construir la trayectoria. Laguna y Martí [20] adaptaron *Path Relinking* en el contexto de GRASP como un método destinado a aumentar la intensificación. El algoritmo de *Path Relinking* opera sobre un conjunto de soluciones, llamado *Elite Set* (ES), que se encuentra ordenado siguiendo un criterio descendente de acuerdo al valor de un criterio de calidad predefinido de cada solución. En este trabajo, consideramos como criterio de calidad el valor de la función objetivo de la solución. En concreto, el *Elite Set* se compone de las soluciones de mayor calidad generadas mediante el algoritmo GRASP. Este diseño generalmente se denomina estático [21], ya que en primer lugar se aplica GRASP para construir el conjunto de élite y posteriormente se aplica *Path Relinking* para explorar trayectorias entre todos los pares de soluciones en el ES. Por otra parte, el diseño dinámico considera la actualización del *Elite Set* cada vez que se explora una trayectoria.

Dadas una solución inicial,  $S_i$  y una solución guía  $S_g$ , *Path Relinking* crea una trayectoria de soluciones intermedias desde  $S_i$  hasta  $S_g$  a través de la inserción en  $S_i$  de características pertenecientes a  $S_g$  que aún no se encuentran en  $S_i$ . En el contexto de  $\alpha$ -SP, se propone la eliminación de un vértice  $v$  que se encuentra en la solución que se está explorando en la trayectoria  $S'$  pero no está incluido en la solución guía, a la vez que se inserta un elemento  $u$  que no se encuentra en  $S'$  pero sí en  $S_g$ . Formalmente, se define entonces el movimiento *swap* de la siguiente manera:

$$\text{Swap}(S', v, u) \leftarrow S' \setminus \{v\} \cup \{u\} : v \in S' \setminus S_g, u \in S_g \setminus S'$$

En cada iteración, *Path Relinking* realiza un movimiento de *swap* que genera una nueva solución intermedia en la trayectoria. Cabe destacar que este movimiento produce, con alta probabilidad, una solución no factible, por lo que será necesario reparar la solución intermedia generada tras un movimiento  $\text{Swap}(S', v, u)$ . Para ello, tras el movimiento, se insertarán de manera aleatoria tantos nodos en la solución como sean necesarios para que la solución vuelva a ser factible.

Existen numerosas variantes de *Path Relinking* que difieren en cómo se construye la trayectoria. Tradicionalmente se consideran dos variantes de *Path Relinking*: *Greedy Path Relinking* (GPR) y *Random Path Relinking* (RPR). GPR, en cada iteración, genera una solución intermedia por cada elemento incluido en  $S_g$  que no está incluido en la solución intermedia  $S'$ , continuando la trayectoria por la mejor solución intermedia de entre las generadas. Por otra parte, RPR selecciona aleatoriamente un elemento de entre los disponibles en  $S_g$  que no están incluidos en  $S'$  y genera una única solución intermedia con un movimiento *swap* donde se incluya dicho vértice. Mientras que GPR se centra en la intensificación, RPR tiene como objetivo la diversificación. De nuevo, la exploración exhaustiva de la trayectoria de GPR hace que no sea un método adecuado para el problema  $\alpha$ -SP, debido al elevado coste computacional. En su lugar, se considera la variante RPR, menos exigente computacionalmente al explorar una única solución en cada etapa de la trayectoria. Para compensar la falta de intensificación en esta etapa, se aplicará el procedimiento de mejora descrito en la Sección II-C a la mejor solución encontrada en la trayectoria.

En este trabajo el *Elite Set* se compone de todas las soluciones generadas en la fase de construcción y mejora. Es importante aclarar que no se permite la entrada de soluciones ya existentes en el *Elite Set*, por lo que todas las soluciones combinadas serán siempre diferentes entre sí.

### III. RESULTADOS COMPUTACIONALES

Esta sección está dedicada a analizar el rendimiento de los algoritmos propuestos y comparar los resultados obtenidos con el mejor método previo encontrado en el estado del arte. Los algoritmos se han desarrollado en Java 9 y todos los experimentos se han llevado a cabo en un Intel Core 2 Duo 2,66 GHz con 4 GB de RAM.

El conjunto de instancias utilizadas en esta experimentación se ha generado utilizando el mismo generador de grafos propuesto en el mejor trabajo previo [22]. Específicamente, los grafos se generan utilizando el modelo Erdős Rényi [23], en el que cada nuevo nodo insertado tiene la misma probabilidad de estar conectado a un nodo ya existente en el grafo. Se ha generado un conjunto de 28 instancias de 100 vértices de diferente densidad (de 200 a 500 aristas).

La experimentación se encuentra dividida en dos partes diferentes: experimentación preliminar y experimentación final. La



primera está diseñada para ajustar el único parámetro del que requiere GRASP,  $\beta$ , que controla la aleatoriedad del método, mientras que la segunda se dedica a analizar el rendimiento de la mejor variante de GRASP junto con Path Relinking en comparación con el mejor algoritmo anterior encontrado en el estado del arte.

Todos los experimentos proporcionan las siguientes métricas: F.O., el valor de la función objetivo promedio; Tiempo (s), el tiempo promedio de cómputo medido en segundos; Desv.(%), la desviación porcentual promedio con respecto a la mejor solución encontrada en el experimento; y #Mejores, el número de veces que un algoritmo alcanza la mejor solución del experimento.

El experimento preliminar considerará un subconjunto de 20 instancias para evitar el sobreajuste del algoritmo. Para ajustar el valor del parámetro, se ha ejecutado la fase de construcción y mejora para generar un total de 100 soluciones por cada instancia, devolviendo la mejor solución encontrada, con  $\beta = \{0,25, 0,50, 0,75, RND\}$ , donde el valor *RND* indica que se obtiene un valor de  $\beta$  aleatorio en cada construcción. La Tabla I muestra los resultados obtenidos para cada valor.

Cuadro I: Rendimiento de GRASP (100 fases de construcción y mejora) con diferentes valores de  $\beta$

$\beta$	F.O.	Tiempo (s)	Desv. (%)	#Mejores
0.25	29.75	18.37	2.31	11
0.50	29.90	18.92	2.91	12
0.75	31.65	18.81	7.09	7
<i>RND</i>	29.80	18.99	3.02	10

Como se puede observar, el valor de  $\beta$  que obtiene los mejores resultados es  $\beta = 0,25$ , que se corresponde con la variante que proporciona una menor aleatoriedad a la construcción. Este resultado parece indicar que el criterio de *closeness* utilizado es muy preciso para identificar los vértices críticos de la red. Por lo tanto, la diversificación se incluirá en mayor medida con la inclusión del método de combinación *Path Relinking*.

El experimento final está diseñado para comparar los resultados obtenidos incluyendo el método de combinación *Path Relinking* respecto al mejor algoritmo encontrado en el estado del arte, esta vez ejecutado sobre el total de instancias disponibles. El mejor algoritmo previo está basado en *Random Walks* combinado con *Markov Chains*. Debido a no haber recibido respuesta por parte de los autores previos, los resultados proporcionados son los obtenidos tras reimplementar detalladamente el método previo [24]. Los resultados se muestran en la tabla II.

Como se puede observar, el mejor algoritmo resulta ser *Path Relinking*, obteniendo el mejor resultado en todas las instancias del conjunto de datos utilizado. Comparando los resultados frente a GRASP, podemos concluir que *Path Relinking* es capaz de mejorar los resultados previos, quedando GRASP a una desviación del 7.42%, a cambio de un mayor coste computacional (18.53 frente a 275.67 segundos). Aún con este incremento en el tiempo de cómputo, sigue requiriendo menos

Cuadro II: Comparativa de los resultados obtenidos por el algoritmo previo (RW) frente a los algoritmos GRASP y *Path Relinking* propuestos en este trabajo.

	F.O.	Tiempo (s)	Desv. (%)	#Mejores
GRASP	31.93	18.53	7.42 %	3
PR	29.43	275.67	0.00 %	28
RW	46.46	721.58	37.81 %	0

de la mitad del tiempo necesitado por el mejor método previo. Cabe destacar que, incluso GRASP de manera aislada, sin considerar *Path Relinking*, obtiene mejores resultados en todas las métricas que el método previo.

Para confirmar que existen diferencias estadísticamente significativas entre los métodos propuestos, se ha llevado a cabo el test no paramétrico de Wilcoxon. El *p*-valor menor que 0.00001 demuestra que sí que existen diferencias entre los métodos, resultando el siguiente ranking: PR (1.05), GRASP (1.95), y RW (3.00). Además, se ha llevado a cabo el test de Wilcoxon con signos para comparar algoritmos por pares. La comparativa de PR frente a RW ha resultado en un *p*-valor menor que 0.00001, al igual que el análisis entre GRASP y PR. Analizando estos resultados, podemos concluir que *Path Relinking* emerge como el mejor algoritmo del estado del arte para el problema del  $\alpha$ -SP.

#### IV. CONCLUSIONES

En este trabajo se ha presentado un algoritmo basado en GRASP para la detección de puntos críticos en redes. Además, las soluciones generadas se combinan utilizando *Path Relinking* para mejorar la calidad de las soluciones obtenidas. Los resultados obtenidos superan a las mejores soluciones encontradas en el estado del arte, todo ello respaldado por test estadísticos. El algoritmo GRASP es capaz de encontrar soluciones de calidad en cortos períodos de tiempo (menos de 20 segundos en promedio), mientras que *Path Relinking* es un procedimiento más costoso computacionalmente pero capaz de mejorar significativamente las soluciones encontradas por GRASP. Ambos métodos obtienen mejores soluciones que el método previo, basado en *Random Walks* combinado con modelos de Markov. La solución propuesta emerge como el mejor método en el estado del arte, pudiendo obtener soluciones de alta calidad en tiempo real con GRASP y mejorarlas posteriormente con *Path Relinking* en aquellas situaciones en las que el tiempo no sea crítico.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad, ref. TIN2015-65460-C2-2-P.

#### REFERENCIAS

- [1] G. Andersson, P. Donalek, R. Farmer, N. Hatziaargyriou, I. Kamwa, P. Kundur, N. Martins, J. Paserba, P. Pourbeik, J. Sanchez Gasca, R. Schulz, A. Stankovic, C. Taylor, and V. Vittal, "Causes of the 2003 major grid blackouts in North America and Europe, and recommended means to improve system dynamic performance," *IEEE Transactions on Power Systems*, vol. 20, no. 4, pp. 1922–1928, 2005.

- [2] P. Crucitti, V. Latora, and M. Marchiori, “Model for cascading failures in complex networks,” *Phys. Rev. E*, vol. 69, p. 045104, 2004.
- [3] U. Feige and M. Mahdian, “Finding small balanced separators.” in *STOC*, J. M. Kleinberg, Ed. ACM, 2006, pp. 375–384.
- [4] M. Mohamed-Sidi, “K-Separator Problem. (Problème de k-Séparateur).” Ph.D. dissertation, Telecom & Management SudParis, Évry, Essonne, France, 2014.
- [5] M. Wachs, C. Grothoff, and R. Thurimella, “Partitioning the Internet.” in *CRiSIS*, F. Martinelli, J.-L. Lanet, W. M. Fitzgerald, and S. N. Foley, Eds. IEEE Computer Society, 2012, pp. 1–8.
- [6] M. Garey and D. Johnson, *Computers and Intractability - A guide to the Theory of NP-Completeness*. San Francisco: Freeman, 1979.
- [7] T. A. Feo and M. G. C. Resende, “A probabilistic heuristic for a computationally difficult set covering problem,” *Operations Research Letters*, vol. 8, no. 2, pp. 67 – 71, 1989.
- [8] T. A. Feo, M. G. C. Resende, and S. H. Smith, “A greedy randomized adaptive search procedure for maximum independent set.” *Operations Research*, vol. 42, no. 5, pp. 860–878, 1994.
- [9] A. Duarte, J. Sánchez-Oro, M. G. C. Resende, F. Glover, and R. Martí, “Greedy randomized adaptive search procedure with exterior path re-linking for differential dispersion minimization.” *Inf. Sci.*, vol. 296, pp. 46–60, 2015.
- [10] J. D. Quintana, J. Sánchez-Oro, and A. Duarte, “Efficient greedy randomized adaptive search procedure for the generalized regenerator location problem.” *Int. J. Comput. Intell. Syst.*, vol. 9, no. 6, pp. 1016–1027, 2016.
- [11] J. Sánchez-Oro, M. Laguna, R. Martí, and A. Duarte, “Scatter search for the bandpass problem,” *Journal of Global Optimization*, vol. 66, no. 4, pp. 769–790, 2016.
- [12] F. W. Glover and G. A. Kochenberger, *Handbook of metaheuristics*. Springer Science & Business Media, 2006, vol. 57.
- [13] F. Glover and M. Laguna, “Tabu search.” in *Handbook of combinatorial optimization*. Springer, 2013, pp. 3261–3362.
- [14] P. Hansen and N. Mladenović, “Variable neighborhood search,” in *Search methodologies*. Springer, 2014, pp. 313–337.
- [15] J. Scott, *Social Network Analysis: A Handbook*. Sage Publications, 2000.
- [16] U. Brandes, “A faster algorithm for betweenness centrality,” *Journal of mathematical sociology*, vol. 25, no. 2, pp. 163–177, 2001.
- [17] L. Page, S. Brin, R. Motwani, and T. Winograd, “The pagerank citation ranking: Bringing order to the web.” Stanford InfoLab, Tech. Rep., 1999.
- [18] M. E. Newman, “The mathematics of networks,” *The new palgrave encyclopedia of economics*, vol. 2, no. 2008, pp. 1–12, 2008.
- [19] F. Glover, *Tabu search and adaptive memory programming – advances, applications, and challenges*. Dordrecht, Massachusetts, USA: Kluwer Academic Publishers, 1996.
- [20] M. Laguna and R. Martí, “Grasp and path re-linking for 2-layer straight line crossing minimization.” *INFORMS Journal on Computing*, vol. 11, no. 1, pp. 44–52, 1999.
- [21] F. Glover, M. Laguna, and R. Martí, “Fundamentals of scatter search and path re-linking,” *Control and cybernetics*, vol. 29, no. 3, pp. 653–684, 2000.
- [22] J. Lee, J. Kwak, H. W. Lee, and N. B. Shroff, “Finding minimum node separators: A markov chain monte carlo method,” in *DRCN 2017 - Design of Reliable Communication Networks; 13th International Conference*, March 2017, pp. 1–8.
- [23] P. Erdős and A. Rényi, “On random graphs,” *Publications Mathematicae*, vol. 6, p. 290, 1959.
- [24] B. Hassibi, M. Hansen, A. Dimakis, H. Alshamary, and W. Xu, “Optimized markov chain monte carlo for signal detection in mimo systems: An analysis of the stationary distribution and mixing time,” *Signal Processing, IEEE Transactions on*, vol. 62, no. 17, pp. 4436–4450, 2014.



# Where facility centers should be located?

A.D. López-Sánchez

*Department of Economics, Quantitative Methods and Economic History*  
*Pablo de Olavide University*  
 Sevilla, Spain  
 adlopsan@upo.es

J. Sánchez-Oro

*Department of Computer Science*  
*Rey Juan Carlos University*  
 Madrid, Spain  
 jesus.sanchezoro@urjc.es

A.G. Hernández-Díaz

*Department of Economics, Quantitative Methods and Economic History*  
*Pablo de Olavide University*  
 Sevilla, Spain  
 agarher@upo.es

M. Laguna

*Leeds School of Business*  
*University of Colorado*  
 Boulder, Colorado  
 laguna@colorado.edu

**Abstract**—Facility location problems aim to determine the best position to place facility centers. This task is not easy since many objectives may be taken into consideration to choose the best possibility and the locations can be substantially different. This paper presents a Scatter Search algorithm with Path Relinking to decide where facility centers should be located depending on the objective functions under consideration. The objectives considered in this study are to minimize the distance between demand points and their nearest facilities, to maximize the number of demand points covered by a facility center and to minimize the maximum distance between demand points and their nearest facilities. Then, this problem is addressed as a three-objective optimization problem and the algorithm proposed is compared against other competitors obtaining promising results according to three different performance metrics.

**Index Terms**—Scatter Search, Path Relinking, Multi-objective optimization problems, Facility location problems

## I. INTRODUCTION

It is not an easy task to locate facility centers since many objectives may be taken into consideration to choose the best possibility. Depending on the objective and the constraints imposed by the decision-maker, the facility centers may be located in different places. Hence, the best location may be substantially different depending on the objective function considered for optimization. Specifically, this work is focused on three common objective functions:  $f_1$ , with the aim of minimizing the average distance between demands and their nearest facilities;  $f_2$ , focused on covering the maximum number of demand points; and  $f_3$ , which minimizes the maximum distance between demand points and their nearest facilities. But what happens when the decision-maker wants to optimize all the objectives at the same time? In such a case, the location problem becomes a multi-objective facility location problem (mo-FLP) in which the objectives are usually in conflict. That is, there is not a single solution that simultaneously

optimizes all objectives, or, in other words, the value of one objective function cannot be improved without deteriorating the value of at least another objective function. Those solutions are known as efficient solutions, non-dominated solutions or Pareto optimal solutions.

The mo-FLP that optimizes  $f_1$ ,  $f_2$ , and  $f_3$ , was recently studied by Karatas and Yakici, see [10]. The authors developed a hybrid algorithm, named ITER-FLOC, that combines branch & bound techniques and iterative goal programming. In particular, authors proposed a different formulation for each considered objective. Initially, lower and upper bounds for each objective are evaluated. Then, for each iteration of the ITER-FLOC algorithm, the location models are solved, verifying if the termination criterion has been achieved. If so, the algorithm ends, returning the Pareto front constructed. Otherwise, the lower and upper bounds of each objective are updated. Prior to executing the next iteration, the location models are updated with additional constraints.

They are able to generate the Pareto optimal solutions with high level of diversity and cardinality. However, the drawbacks are the requirement of preference information since goal programming is considered an *a priori* method and its slowness because it is an exact algorithm that needs to be solved multiple times (one for each considered goal). Additionally, the method requires from several input parameters that can difficult the scalability of the algorithm for new datasets.

Here, the mo-FLP is addressed using a Scatter Search algorithm combined with Path Relinking (SSPR). The output of the algorithm is the approximation of the Pareto front containing efficient solutions. A variety of optimization problems has been solved and the computational results indicate that the Scatter Search algorithm is able to find the Pareto set in a simple run within short computational time.

This work is structured as follows. Section II describes the problem. Section III gives details of the Scatter Search algorithm with Path Relinking implemented to solve the problem under consideration. Section IV presents the computational results. Finally, Section V summarizes the paper and discusses

J. Sánchez-Oro is supported by the Spanish Ministry of "Economía y Competitividad", Grant Refs. TIN2015-65460-C2-2-P. A.D. López-Sánchez and A.G. Hernández-Díaz acknowledge support from the Spanish Ministry of Science and Innovation through Project ECO2016-76567-C4-1-R.

future work.

## II. LOCATION PROBLEM DEFINITION

Let  $I = \{1 \dots m\}$  be the set of available locations to host a facility center and  $J = \{1 \dots n\}$  the set of demand points that requires to be covered by a facility center. Each demand point  $i \in I$  has an associated weight  $w_i$  that represents the cost of satisfying its necessity with a facility center. Additionally, let  $d_{ij} \geq 0$  be the distance between a candidate location  $i \in I$  and a demand point  $j \in J$ . The distance is evaluated as the length of the shortest path that connects  $x$  with  $y$ . A solution  $S$  for a facility location problem is then represented as the set of  $p$  candidate locations to host a facility center, and the objective of the problem is to find a solution with the optimum value with respect to one or more objective function.

This work is focused on optimizing three different objective functions simultaneously, becoming a multi-objective problem. The first considered objective function,  $f_1$ , is focused on minimizing the average weighted distance between the demand points and their nearest facility center, which can be found in the literature as the  $p$ -Median Problem (pMP). Given a solution  $S$ , the evaluation of  $f_1$  is formally defined as:

$$f_1(S) \leftarrow \frac{1}{n} \sum_{j \in J} w_j \cdot d_{i^*j}, \text{ where } i^* \leftarrow \arg \min_{i \in S} d_{ij}$$

The second objective function,  $f_2$ , tries to maximize the number of demand points whose necessity is satisfied by the selected candidate locations, which is usually referenced as the Maximal Coverage Location Problem (MCLP). A demand point is covered by a facility center if the distance between them is smaller or equal than a predefined threshold  $r$ . More formally,

$$f_2(S) \leftarrow \left| \left\{ j \in J : d_{i^*j} \leq r, \text{ where } i^* \leftarrow \arg \min_{i \in S} d_{ij} \right\} \right|$$

The third objective function,  $f_3$ , is intended to minimize the maximum distance between the demand points and the facility centers, which result in the  $p$ -Center Problem (pCP). This objective function is formally defined as:

$$f_3(S) \leftarrow \max_{j \in J} d_{i^*j}, \text{ where } i^* \leftarrow \arg \min_{i \in S} d_{ij}$$

Some of the first studies dealing the previous location problems were proposed by [2], [8], [9].

## III. SCATTER SEARCH ALGORITHM WITH PATH RELINKING

Scatter Search (SS), first proposed by Glover, see [5], is a metaheuristic framework which generates, maintains, and transforms a reference set of solutions,  $RefSet$ . It has been successfully applied to a large variety of optimization problems [12], [13]. Figure 1 depicts the general scheme for Scatter Search.

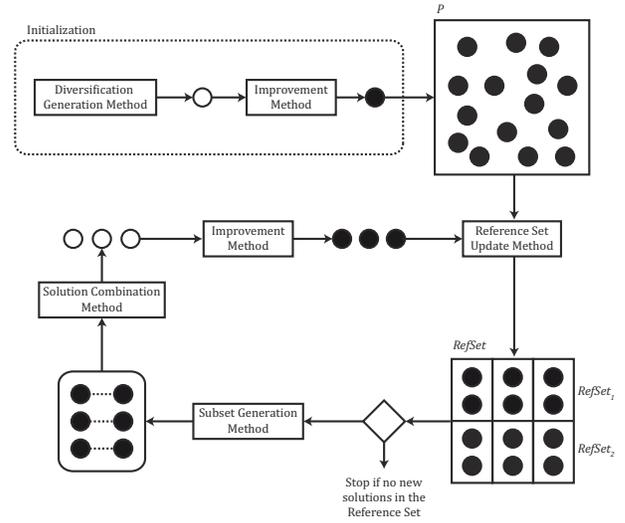


Fig. 1. Scatter Search algorithm.

The method firstly generates an initial population  $P$ . These solutions are generated using a diversification generation method (Section III-A). Then, a local optimum for each solution is found by an improvement method (Section III-B). It is important to remark that there are not repeated solutions in the initial population  $P$ .

Traditional implementations of Scatter Search constructs the reference set  $RefSet$  with the  $\beta/2$  best solutions of set  $P$  in terms of objective function value. This work adapt this criterion for a multi-objective approach, by dividing the  $RefSet$  in three subsets,  $RefSet_1$ ,  $RefSet_2$ , and  $RefSet_3$ , with  $|RefSet_1| = |RefSet_2| = |RefSet_3| = \beta$ . In particular,  $RefSet_1$  initially contains the best  $\beta/2$  solutions with respect to  $f_1$ , while  $RefSet_2$  and  $RefSet_3$  contains the best  $\beta/2$  ones with respect to  $f_2$  and  $f_3$ , respectively. The remaining  $\beta/2$  solutions for each  $RefSet$  are selected as the most diverse solutions among the remaining solutions in  $P$ . Diversity between a solution  $S$  and the  $RefSet$  under construction is measured as the minimum distance between  $S$  and every solution in the  $RefSet$ , considering the distance between two solutions as the number of candidate locations that differs in both solutions.

Once the  $RefSet$  has been created, Scatter Search selects the subsets of reference solutions that will be combined with the aim of finding new trial solutions. The most common implementation of the subset generation method consists of combining all pairs of solutions included in the  $RefSet$ . Considering that we maintain three  $RefSet$ , this implementation would be rather computationally demanding. Instead, we generate all pairs of solutions  $(S, S')$  such that  $S$  and  $S'$  belong to different  $RefSet$  (i.e.,  $S \in RefSet_i$ ,  $S' \in RefSet_j$ , with  $1 \leq i, j \leq 3 \wedge i \neq j$ ).

The solution combination method (Section III-C) is designed to combine all the subsets generated in the previous step in order to generate new solutions that become candidate for entering in the  $RefSet$ . Regarding that the moFLP considers



three different objective functions, a local optimum is found with respect to each one of the by using the improvement method. Then, each improved solution is evaluated for being included in its corresponding *RefSet*. In particular, a solution enters in the *RefSet* if it is better than the worst solution already in the *RefSet*. It is worth mentioning that the size of the *RefSet* remains constant throughout the whole process. Therefore, the new solution must replace another one. Specifically, the new solution replaces the most similar solution already in the *RefSet* that presents a quality smaller or equal than it.

Scatter Search iterates until a stopping criterion is met. The algorithm proposed in this work stops when it has not been possible to include new solutions in any of the *RefSet*, returning the set of efficient solutions found during the search.

#### A. Diversification Generation Method

The diversification generation method (DGM) is designed for creating an initial set of solutions  $P$  which will become the source for creating the initial *RefSet*. On the one hand,  $P$  should contain high quality solutions in order to guide the search through promising regions of the search space. On the other hand, solutions in  $P$  must be diverse enough to provide different solutions for the combination stage, thus diversifying the search.

We propose three different constructive methods in this work,  $DGM_1$ ,  $DGM_2$ , and  $DGM_3$  each one of them focused on generating promising solutions for  $f_1$ ,  $f_2$ , and  $f_3$ , respectively. With the aim of increasing the diversity of the set of solutions constructed, we propose a Greedy Randomized Adaptive Search Procedure (GRASP). GRASP is a multi-start methodology originally proposed by [4], that is conformed by two stages: construction and improvement. The former consists of a greedy, randomized, and adaptive construction of a solution while the latter is designed for finding a local optimum with respect to a predefined neighborhood.

The diversification generation method proposed in this work follows a traditional GRASP construction scheme. The method initially creates a candidate list  $CL$  with all the candidate locations available to host a facility. Then, each candidate location is evaluated with a greedy function that estimates the relevance of locating a facility in that candidate. For this problem, we propose a different greedy function for each objective function considered  $f_1$ ,  $f_2$ ,  $f_3$ . In particular, the greedy function value for each candidate location is calculated as the corresponding objective value ( $f_1$ ,  $f_2$ , and  $f_3$ , respectively) if the location is assigned to host a facility. After evaluating all the candidates, the method calculates a threshold  $\mu$  as follows:

$$\mu \leftarrow g_{\min} + \alpha \cdot (g_{\max} - g_{\min})$$

This threshold is used for constructing the restricted candidate list  $RCL$ , that contains the most promising candidates to host a facility. In particular, the  $RCL$  is conformed with all the candidate locations whose greedy function value is smaller or equal than threshold  $\mu$ . For each iteration, a random element is selected from the  $RCL$  to host the next facility. Notice

that  $\alpha \in [0, 1]$  is a parameter of the method that controls the randomness of the constructive procedure. On the one hand, if  $\alpha = 0$  then the  $RCL$  would contain the candidates with the minimum greedy function value, being a totally greedy procedure. On the other hand, when  $\alpha = 1$ , the  $RCL$  contains all the candidate locations in  $CL$ , becoming a random procedure. Then, it is interesting to find a balance between diversification and intensification by varying the value of the  $\alpha$  parameter. A new candidate is selected in each iteration following this strategy until  $p$  candidate locations already host a facility.

#### B. Improvement Method

The diversification generation method is designed to produce not only high quality solutions, but also diverse ones. The increase in the diversity of the solutions generated usually implies a decrease in the quality of those solutions. Therefore, it is interesting to use a local improving method designed to find a local optimum with respect to a previously defined neighborhood.

Regarding the algorithmic proposal for the moFLP, the solutions included in the set of initial solutions  $P$  can be further improved using a local optimizer. Scatter Search is a versatile methodology than allows using different types of optimizers, from local search methods to complete metaheuristics like Tabu Search or VNS, among others (see [REF AUTOCITA] for some successful application of complete metaheuristics in the improving phase). For this problem, we propose a local search method designed to improve the quality of the initial solutions and of those resulting from the combination method. The computational effort required to evaluate the solutions makes the use of complete metaheuristics not suitable for the problem under consideration.

Prior to define the local improvement method, it is necessary to present the neighborhood of solutions considered by the method. We define the neighborhood  $N(S)$  as all the solutions that can be reached from an initial solution  $S$  by performing a single *interchange* move, which consists of removing a selected location and replacing it with any non-selected facility location. More formally,

$$N(S) \leftarrow \{S' : S' \leftarrow S \setminus \{v\} \cup \{u\} \forall v \in S \forall u \in V \setminus S\}$$

Having defined  $N(S)$ , the local search method proposed visits all neighbor solutions in a random order and replaces the incumbent solution with the first neighbor solution with a better objective function value. It is worth mentioning that the local search proposed follows a first improvement approach in order to reduce the computational effort required to apply it. Specifically, if an interchange move results in an improvement with respect to the objective function being optimized, the move is performed, restarting the search with the new best solution. This strategy reduces the complexity of the search since the opposite strategy, best improvement, requires the complete exploration of the neighborhood in each iteration to select the best solution in the neighborhood.

In the framework of Scatter Search, the improvement method is applied in two different stages, see Figure 1. First of all, it is used for locally improving the solutions that are included in the initial population. It is worth mentioning that the set  $P$  is divided into three subsets (one for each objective function), so the local search method improves each solution with respect to the objective function considered for its construction.

The local search method is also applied to those solutions resulting from the combination stage. As it is described in Section III-C, the combination stage does not produce local optimum with respect to any neighborhood, so the resulting solutions can be further improved with a local optimizer. Specifically, for each solution derived from the combination stage, three local optima are found, one for each objective function of the moFLP, respectively. Then, each improved solution is evaluated to be included in the *RefSet*.

### C. Solution Combination Method

The solution combination method is responsible for generating new solutions in each iteration of the Scatter Search algorithm by combining two or more solutions that are already in the *RefSet*. The combination can be performed following different strategies, from genetic operators to the generation of paths between solutions.

In this work we propose using Path Relinking (PR) [6], [7] as a combination method, which has been successfully applied in several recent works [1], [3]. Given an initial and a guiding solution,  $s_i$  and  $s_g$ , respectively, PR constructs a path of solutions that starts in  $s_i$  and finishes in  $s_g$ . The objective of PR is iteratively transform the initial solution into the guiding one. The transformation is achieved by adding attributes of the guiding solution into the initial one while removing those attributes of the initial solution that are not present in the guiding one, stopping when  $s_i$  becomes  $s_g$ .

There exist several strategies for combining solutions in the context of Path Relinking: Random Path Relinking, Greedy Path Relinking, or Greedy Randomized Path Relinking, among others. Most of the greedy variants require the exploration of all the alternative solutions in each step of the path, in order to select the most promising solution to continue the path. However, these strategies are usually very time consuming, increasing the required computing time to execute the algorithm. We have selected the Random Path Relinking variant in order to accelerate the proposed algorithm, thus increasing the diversification of the search.

Starting from the initial solution  $s_i$ , Random Path Relinking generates a random solution in the neighborhood defined in Section III-B that inserts a new candidate location which is already in the guiding solution, removing one of the candidate locations currently in  $s_i$  that does not belongs to  $s_g$ . Notice that after a certain number of iterations, the initial solution would become the guiding one, since in each iteration the initial solution will have an additional candidate location in common with  $s_g$ .

## IV. COMPUTATIONAL RESULTS

In this section the numerical results are shown in order to prove the superiority of the Scatter Search algorithm with Path Relinking in comparison to the algorithm proposed by Karatas and Yakici in [10].

Since the original instances are not available, we request the code from the previous work in order to have a fair comparison. Additionally, 20 new instances of sizes were generated following the instructions of the previous work. The instances are divided into three sets depending on their size: small, those with 20 candidate locations and 50 demand points; medium, with 50 candidate locations and 100 demand points; and large, with 200 candidate locations and 400 demand points. Table I summarizes the following parameters of the instances generated:

- $m$ : number of candidate locations to host a facility
- $n$ : number of demand points
- $p$ : number of candidate locations that must be selected
- $r$ : radius in which a facility is covering a demand point

We refer the reader to [10] for a more detailed description on the instance structure.

TABLE I  
PARAMETERS SETTING FOR THE INSTANCES.

Parameter	Small	Medium	Large
m	20	50	200
n	50	100	400
p	5	10	15
r	20	15	10

All the algorithms proposed in this work have been implemented using Java 8 and the experiments were performed on an Intel Core i7 920 (2.67 GHz) with 8 GB RAM. It is worth mentioning that the previous algorithm has been also executed in the same computer in order to have a fair comparison.

Table II shows average results of both the Scatter Search with Path Relinking algorithm proposed (SSPR) and the best previous method (ITER-FLOC) the 20 instances. Regarding the multi-objective nature of the problem under consideration, we have considered using the following metrics: coverage, C; hypervolume, HV; epsilon indicator, Eps; and CPU time. Results in Table II shows the superiority of the SSPR algorithm.

If we focus on the coverage metric, it can be hold that the proportion of solutions covered by the SSPR algorithm is larger than the proportion of solution covered by the ITER-FLOC algorithm. Furthermore, the SSPR scales better than the ITER-FLOC algorithm, as it can be seen with the increase of the solutions covered by SSPR when increasing the size of the instance, achieving a 100% of coverage when analyzing the set of large instances.

Regarding the hypervolume (larger values are better) and the epsilon indicator (smaller values are better), we can conclude that SSPR consistently obtains better results than the ITER-FLOC algorithm. Again, the larger the instance set, the better



the results of SSPR when compared against ITER-FLOC. This behavior suggests that SSPR is a more adequate algorithm for real-life problems with a large number of candidate locations and demand points.

Finally, if we consider the computing time, we can see that ITER-FLOC is equivalent or even faster when considering small or medium instances, but the performance does not scale good with the size of the instance. Therefore, when solving the largest instances the proposed SSPR algorithm is considerably faster than the ITER-FLOC approach.

TABLE II  
AVERAGE RESULTS.

	C(SSPR,ITER-FLOC)	C(ITER-FLOC,SSPR)
Small	<b>0.61</b>	0.17
Medium	<b>0.82</b>	0.00
Large	<b>1.00</b>	0.00
	HV(SSPR)	HV(ITER-FLOC)
Small	<b>0.28</b>	0.07
Medium	<b>0.52</b>	0.12
Large	<b>0.81</b>	0.20
	Eps(SSPR)	Eps(ITER-FLOC)
Small	<b>0.44</b>	0.78
Medium	<b>0.14</b>	0.70
Large	<b>0.00</b>	0.50
	CPU(SSPR)	CPU(ITER-FLOC)
Small	<b>6.41</b>	7.25
Medium	72.66	<b>19.74</b>
Large	<b>1920.53</b>	5920.34

## V. CONCLUSIONS

A population-based metaheuristic with a method for combining solutions have been proposed for a multi-objective facility location problem (mo-FLP) which considers three different objectives of interest in real-life problems: to minimize the average distance between demands and their nearest facilities, to maximize the total number of demand points covered, and to minimize the maximum distance between demand points and their nearest facilities.

The computational experiments shows how Scatter Search with Path Relinking is a suitable algorithm for solving large scale instances, performing better in both quality and computing time than the best previous algorithm found in the state of the art. The experiments have been performed in the same computer in order to have comparable results, concluding that SSPR outperforms the best previous method considering all the metrics presented.

## ACKNOWLEDGMENT

J. Sánchez-Oro is supported by the Spanish Ministry of "Economía y Competitividad", Grant Refs. TIN2015-65460-C2-2-P and TIN2014-54806-R.

A.D. López-Sánchez and A.G. Hernández-Díaz acknowledge support from the Spanish Ministry of Science and Innovation through Project ECO2016-76567-C4-1-R.

## REFERENCES

- [1] V. Campos, R. Martí, J. Sánchez-Oro, A. Duarte, "GRASP with path relinking for the orienteering problem", *Journal of the Operational Research Society*, vol. 65, pp. 1800–1813, 2014.
- [2] R. Church, and C.R. Velle, "The maximal covering location problem," *Papers in Regional Science*, vol. 32, pp. 101–118, 1974.
- [3] A. Duarte, J. Sánchez-Oro, M.G.C. Resende, F. Glover, R. Martí, "Greedy randomized adaptive search procedure with exterior path relinking for differential dispersion minimization", *Information Sciences*, vol. 296, pp. 46–60, 2015.
- [4] T. Feo, M.G.C. Resende. "A probabilistic heuristic for a computationally difficult set covering problem", *Operations Research Letters*, vol. 8, pp. 67–71, 1989.
- [5] F. Glover, "Heuristics for integer programming using surrogate constraints," *Decision Sciences*, vol. 8, pp. 156–166, 1977.
- [6] F. Glover "Tabu search and adaptive memory programming – advances, applications, and challenges," Kluwer Academic Publishers, 1996.
- [7] F. Glover, and M. Laguna, "Tabu Search," Kluwer Academic Publishers, 1997.
- [8] S.L. Hakimi, "Optimum Locations of Switching Centers and the Absolute Centers and Medians of a Graph," *Operations Research*, vol. 12, pp. 450–459, 1964.
- [9] S.L. Hakimi, "Optimum Distribution of Switching Centers in a Communication Network and Some Related Graph Theoretic Problems," *Operations Research*, vol. 13, pp. 462–475, 1965.
- [10] M. Karatas, and E. Yalc, "An iterative solution approach to a multi-objective facility location problem," *Applied Soft Computing*, vol. 62, pp. 272–287, 2018.
- [11] R. Martí, M. Laguna, and F. Glover. "Principles of scatter search," *European Journal of Operational Research*, vol. 169, pp. 359–372, 2006.
- [12] J. Sánchez-Oro, M. Laguna, R. Martí, and A. Duarte. "Scatter Search for the Bandpass Problem", *Journal of Global Optimization*, vol. 66(4), pp. 769–790, 2016
- [13] J. Sánchez-Oro, A. Martínez-Gavara, M. Laguna, A. Duarte, and R. Martí. "Variable neighborhood scatter search for the incremental graph drawing problem", *Computational Optimization and Applications*, vol. 68(3), pp. 775–797, 2017
- [14] J.J. Sylvester, "A Question in the Geometry of Situation," *Quarterly Journal of Pure and Applied Mathematics*, vol. 1, 1857.



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 2.2:  
SCATTER SEARCH Y VNS







# Encontrando grafos bipartitos completos mediante Búsqueda de Vecindad Variable

Juan David Quintana  
Dept. Computer Sciences  
Universidad Rey Juan Carlos  
Madrid, España  
juandavid.quintana@urjc.es

Jesús Sánchez-Oro  
Dept. Computer Sciences  
Universidad Rey Juan Carlos  
Madrid, España  
jesus.sanchezoro@urjc.es

Abraham Duarte  
Dept. Computer Sciences  
Universidad Rey Juan Carlos  
Madrid, España  
abraham.duarte@urjc.es

**Resumen**—El Problema del Máximo Biclique Balanceado, o *Maximum Balanced Biclique Problem* (MBBP), consiste en encontrar el biclique de tamaño máximo inducido por un grafo bipartito no completo. Se tiene la restricción adicional de que tanto el tamaño del grafo de partida como el biclique inducido tienen el mismo número de vértices en cada una de sus capas, por lo tanto se dice que son balanceados. Algunas de sus aplicaciones se dan en el diseño de circuitos en integración a gran escala (VLSI) o el diseño de sistemas nanoelectrónicos, entre otras. Se ha demostrado que este problema de optimización combinatoria es NP-Duro. En la literatura se han propuesto diversas heurísticas para solucionarlo, generalmente basadas en la eliminación de vértices, y más recientemente se ha propuesto un algoritmo evolutivo que tiene los mejores resultados en la literatura. En este trabajo se propone el uso de la metodología RVNS para abordar este problema. Esta elección se justifica en la dificultad para diseñar una búsqueda local efectiva para este problema.

**Index Terms**—biclique, Reduced VNS, bipartito.

## I. INTRODUCCIÓN

Sea  $G(L, R, E)$  un grafo bipartito balanceado en el que  $L$  y  $R$  son dos conjuntos (o capas) de vértices con la misma cardinalidad (i.e.,  $|L| = |R| = n$ ) y  $E$  es el conjunto de aristas. Al ser un grafo bipartito,  $L \cap R = \emptyset$ , una arista solo puede conectar un vértice  $v \in L$  con otro  $u \in R$ , i.e.,  $\forall (v, u) \in E \ v \in L \wedge u \in R$ . Además, definimos un biclique  $B(L', R', E')$  como el grafo inducido por  $G$ , en el que  $L' \subset L$ ,  $R' \subset R$ , de forma que todo vértice  $v \in L'$  está conectado a todo vértice  $u \in R'$ . Dicho de otra forma,  $B$  es un grafo bipartito completo, también llamado biclique.

Dado un grafo bipartito balanceado  $G(L, R, E)$ , este trabajo se centra en resolver el Problema del Máximo Biclique Balanceado, más conocido como *Maximum Balanced Biclique Problem* (MBBP) en inglés, que consiste en identificar un biclique balanceado  $B^*(L', R', E')$  con el mayor número de vértices por capa. En otras palabras, el objetivo del MBBP es maximizar la cardinalidad de los conjuntos  $L'$  y  $R'$ .

La Figura 1 presenta un ejemplo de grafo bipartito con 8 vértices, 13 aristas, y dos posibles soluciones para el MBBP. La figura 1(b) muestra una solución  $B_1(L_1, R_1, E_1)$  con dos vértices en cada capa. En este caso,  $L_1 = \{A, B\}$ , y  $R_1 = \{F, G\}$ . Las aristas que pertenecen al biclique inducido

se representan con una línea continua, mientras que aquellas con un extremo fuera de la solución se representan con una línea discontinua. Obsérvese que no es posible insertar nuevos vértices en la solución, ya que en dicho caso el grafo bipartito inducido resultante no sería un biclique balanceado. Por ejemplo, no es posible añadir los vértices E o H porque no son adyacentes a los vértices B y A, respectivamente. Además, no es posible añadir vértices en la capa  $L_1$  ya que el biclique inducido no sería balanceado (i.e.,  $|L_1| \neq |R_1|$ ).

La figura 1(c) muestra una solución  $B_2(L_2, R_2, E_2)$  de mejor calidad, ya que tiene 3 vértices en cada capa. En concreto,  $L_2 = \{B, C, D\}$ , y  $R_2 = \{F, G, H\}$ . De nuevo, no es posible añadir más vértices sin violar la restricción de tener un biclique balanceado.

Se ha demostrado que este problema es NP-Duro en varios trabajos previos [1]–[3]. Algunos resultados teóricos proponen cotas para el tamaño máximo que la solución óptima puede alcanzar [4], y se demostró difícil de aproximar dentro de un determinado factor [5].

Los grafos biclique han demostrado ser de utilidad en varias aplicaciones prácticas, la mayoría de ellas en el campo de la biología: agrupación de datos de microarrays [6]–[8], optimización de la reconstrucción del árbol filogenético [9], entre otras [10]–[12]. En particular, el MBBP tiene aplicaciones adicionales en diversos campos: diseño eficiente de circuitos en integración a gran escala (VLSI) [13], o el diseño de nuevos sistemas nanoelectrónicos [14]–[16], entre otras.

A pesar de las aplicaciones prácticas del MBBP, no se han propuesto muchos algoritmos eficientes para solucionarlo, principalmente debido a la dificultad del problema. Sin embargo, si del MBBP eliminamos la restricción de que la solución deba ser balanceada, entonces el problema resultante sería resoluble en tiempo polinómico [17], pero la mayoría de las soluciones serían desbalanceadas, haciendo que los resultados no sean adaptables al problema que estamos considerando.

La mayoría de los planteamientos previos siguen un enfoque destructivo en el que la solución inicial contiene todos los vértices y la heurística elimina iterativamente vértices en  $L'$  y  $R'$  hasta que la solución resultante es factible. Estos algoritmos se diferencian entre sí principalmente por el criterio

Este trabajo ha sido financiado parcialmente por el Ministerio de Economía y Competitividad, ref. TIN2015-65460-C2-2-P.

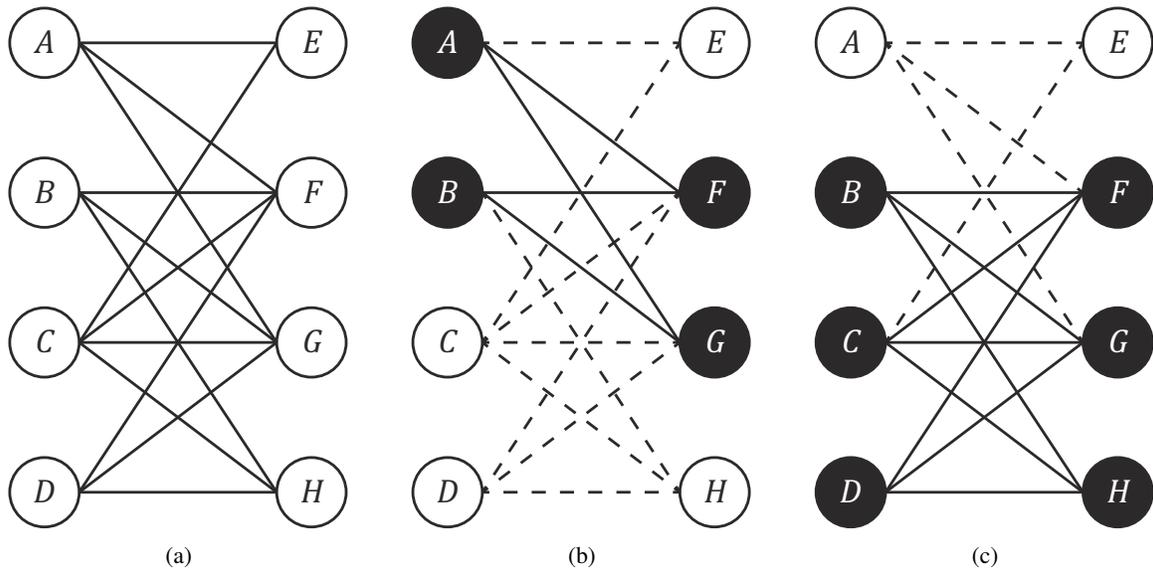


Figura 1: 1(a) Grafo bipartito con 8 vértices y 13 aristas, 1(b) una solución factible con 2 vértices en cada capa ( $A$  y  $B$  en  $L'$ ,  $F$  y  $G$  en  $R'$ ), y 1(c) una solución distinta con 3 vértices en cada capa ( $B$ ,  $C$  y  $D$  en  $L'$ ,  $F$ ,  $G$ , y  $H$  en  $R'$ )

utilizado para elegir los vértices a eliminar. En particular, [14] selecciona los vértices de mayor grado, mientras que [15] elimina los de mayor número de vértices de mínimo grado en la otra capa. Además, algunos algoritmos han intentado combinar ambos criterios [18], [19]. El mejor algoritmo encontrado en la literatura consiste en un algoritmo evolutivo [20] que propone un nuevo operador de mutación así como una nueva búsqueda local para mejorar la calidad de las soluciones generadas.

El resto de este artículo está organizado de la siguiente forma: la Sección II describe la propuesta algorítmica para el MBBP; la Sección III presenta los experimentos realizados para evaluar la calidad de la propuesta algorítmica; y la Sección IV plantea las conclusiones de esta investigación.

## II. REDUCED VARIABLE NEIGHBORHOOD SEARCH

La Búsqueda de Vecindad Variable (VNS por sus siglas en inglés *Variable Neighborhood Search*) [21] es una metaheurística basada en cambios sistemáticos de vecindad. Al ser una metaheurística, no garantiza la optimalidad de las soluciones obtenidas, pero se centra en obtener soluciones de alta calidad en un tiempo razonable de cómputo. La constante evolución de VNS ha dado lugar a diversas variantes, entre la que podemos destacar *Basic VNS*, *Reduced VNS (RVNS)*, *Variable Neighborhood Descent (VND)*, *General VNS*, *Skewed VNS*, *Variable Neighborhood Decomposition Search*, entre otras.

La mayoría de las variantes se diferencian en la forma de explorar las vecindades establecidas. En particular, *Variable Neighborhood Decomposition Search* realiza una exploración totalmente determinista del espacio de soluciones, mientras que la exploración realizada por RVNS es totalmente estocástica. Algunas variantes combinan cambios de vecindad

tanto deterministas como estocásticas (e.g., *Basic VNS*, *General VNS*).

Como se menciona en trabajos previos [19], [20], diseñar una búsqueda local para el MBBP es una tarea difícil principalmente por la complejidad de mantener una solución factible (i.e. un biclique balanceado) tras eliminar o añadir vértices en una solución previa. En otras palabras, el MBBP no es idóneo para proponer métodos de búsqueda local que permitan encontrar un óptimo local en relación a una solución determinada. Por lo tanto, este trabajo propone un algoritmo *Reduced VNS*, que se basa en la exploración aleatoria de las vecindades establecidas.

RVNS es una variante de VNS útil para instancias grandes en las que la búsqueda local es muy costosa en tiempo, o para aquellos problemas en los que no es fácil diseñar un método de búsqueda local.

---

### Algoritmo 1 $RVNS(B, k_{\max}, t_{\max})$

---

```

1: repeat
2:    $k \leftarrow 1$ 
3:   while  $k \leq k_{\max}$  do
4:      $B' \leftarrow Shake(B, k)$ 
5:      $k \leftarrow NeighborhoodChange(B, B', k)$ 
6:   end while
7: until  $CPUTime() \leq t_{\max}$ 
8: return  $B$ 

```

---

El algoritmo requiere de dos parámetros de entrada:  $B$ , una solución factible de partida, que se puede generar aleatoriamente o mediante un procedimiento constructivo más elaborado; y  $k_{\max}$ , la vecindad máxima a explorar.

Cada iteración de RVNS empieza desde la vecindad inicial (paso 2). A continuación, el método explora cada una de las vecindades establecidas (pasos 3-6) de la siguiente forma. En



primer lugar, el método genera una solución al azar  $B'$  en la vecindad  $k$  de la solución actual  $B$  con el método *Shake* (paso 4). Luego el método *NeighborhoodChange* (paso 5) se encarga de seleccionar la siguiente vecindad a explorar. En particular, si la nueva solución  $B'$  es mejor que la solución de partida  $B$ , entonces se actualiza ( $B \leftarrow B'$ ), y reinicia la búsqueda desde la vecindad inicial ( $k \leftarrow 1$ ). En caso contrario, la búsqueda continúa con la siguiente vecindad ( $k \leftarrow k + 1$ ). Una iteración de RVNS termina cuando se ha alcanzado la vecindad máxima establecida  $k_{\text{máx}}$ . Es importante mencionar que la vecindad máxima utilizada en RVNS es generalmente pequeña debido a la naturaleza aleatoria del método *Shake*, ya que un valor mayor para  $k_{\text{máx}}$  produciría resultados equivalentes a reiniciar la búsqueda desde una nueva solución inicial. El método RVNS se ejecuta hasta que se alcanza un tiempo límite de cómputo  $t_{\text{máx}}$ .

#### II-A. Procedimiento constructivo

La solución inicial para RVNS puede ser generada al azar o con un procedimiento constructivo más elaborado. Este trabajo propone un procedimiento constructivo basado en *Greedy Randomized Adaptive Search Procedure* (GRASP) [22]. Esta metodología considera una función voraz que evalúa la importancia de insertar cada vértice en la solución a construir. En el Algoritmo 2 se presenta el pseudocódigo del procedimiento constructivo propuesto.

---

#### Algoritmo 2 $Construct(G = (L, R, E), \alpha)$

---

```

1: function UPDATELAYER( $CL_1, CL_2, \alpha$ )
2:    $g_{\text{mín}} \leftarrow \min_{v \in CL_1} g(v)$ 
3:    $g_{\text{máx}} \leftarrow \max_{v \in CL_1} g(v)$ 
4:    $\mu \leftarrow g_{\text{mín}} + \alpha \cdot (g_{\text{máx}} - g_{\text{mín}})$ 
5:    $RCL \leftarrow \{v \in CL_1 ; g(v) \leq \mu\}$ 
6:    $v \leftarrow \text{Random}(RCL)$ 
7:    $CL_1 \leftarrow CL_1 \setminus \{v\}$ 
8:    $CL_2 \leftarrow CL_2 \setminus \{u \in CL_2 : (v, u) \notin E\}$ 
9:   return  $v$ 
10: end function
11:  $v \leftarrow \text{Random}(L)$ 
12:  $L' \leftarrow \{v\}$ 
13:  $CL_L \leftarrow L \setminus \{v\}$ 
14:  $CL_R \leftarrow \{u \in R : (v, u) \in E\}$ 
15: while  $CL_L \neq \emptyset$  and  $CL_R \neq \emptyset$  do
16:    $v_r \leftarrow \text{UPDATELAYER}(CL_R, CL_L, \alpha)$ 
17:    $R' \leftarrow R \cup \{v_r\}$ 
18:    $v_l \leftarrow \text{UPDATELAYER}(CL_L, CL_R, \alpha)$ 
19:    $L' \leftarrow L \cup \{v_l\}$ 
20: end while
21: return  $B = (L', R', \{(v, u) v \in L' \wedge u \in R'\})$ 

```

---

El método empieza por seleccionar un vértice al azar de la capa  $L$  (paso 11), insertarlo la capa correspondiente  $L'$  de la solución (paso 12). Entonces, se crean dos listas de candidatos (CL), una por cada capa del grafo (paso 13-14). Obsérvese que ambas listas de candidatos solo contienen aquellos vértices de cada capa que pueden ser seleccionados manteniendo

la solución factible (i.e., la solución es un grafo bipartito completo). Por lo tanto, en este paso inicial,  $CL_L$  contiene todos los vértices de  $L$  exceptuando al vértice seleccionado  $v$ . Por otra parte,  $CL_R$  contiene todos los vértices adyacentes a  $v$  en  $R$ , ya que de otra forma la solución no sería un grafo bipartito completo. A continuación, el método añade un vértice en la capa  $R'$  y luego en  $L'$  iterativamente, mientras que queden candidatos en ambas capas (paso 16-19).

La selección del vértice siguiente se describe en la función *UpdateLayer* que requiere de tres parámetros: la lista de candidatos desde la que se debe elegir el vértice,  $CL_1$ , la lista de candidatos de la otra capa,  $CL_2$ , y el parámetro  $\alpha$  que determina el grado de voracidad / aleatoriedad de la selección. Una función voraz  $g$  que evalúa la calidad de un vértice candidato  $v$  debe ser definida. En este trabajo, proponemos como función el número de vértices adyacentes en la lista de candidatos de la capa opuesta. Formalmente,

$$g(v, CL) \leftarrow \{u \in CL : (v, u) \in E\}$$

El primer paso para seleccionar el vértice siguiente consiste en obtener los valores mínimo ( $g_{\text{mín}}$ ) y máximo ( $g_{\text{máx}}$ ) para la función voraz (paso 2-3). A continuación, se construye (paso 5) la lista de candidatos restringida ( $RCL$ ) con aquellos vértices cuyo valor de la función objetivo sea mayor o igual que el umbral hallado previamente  $\mu$  (paso 4). Los valores para el parámetro  $\alpha$  están en el rango 0–1, donde  $\alpha = 0$  implica que el método es totalmente aleatorio, y  $\alpha = 1$  transforma el algoritmo en completamente voraz. El siguiente vértice se selecciona al azar de  $RCL$  (paso 6), y luego se actualiza cada lista de candidatos. En particular,  $CL_1$  se actualiza mediante quitar el vértice seleccionado de sí mismo, mientras  $CL_2$  se actualiza quitando aquellos vértices que no son adyacentes a  $v$ , debido a que no pueden ser elegidos en iteraciones futuras sin que la solución se vuelva infactible.

#### II-B. Shake

El método *Shake* es una etapa dentro de la metodología VNS diseñada para escapar de óptimos locales encontrados durante la fase de búsqueda. Consiste en perturbar aleatoriamente una solución con el objetivo de explorar regiones más amplias en el espacio de búsqueda. Esta fase de la metodología VNS se centra en diversificar la búsqueda.

Dada una vecindad  $k$ , el método *Shake* propuesto en este trabajo elimina  $k$  elementos al azar de cada capa. La solución resultante es factible pero el valor de función objetivo siempre es menor, ya que se reduce el número de vértices seleccionados.

Teniendo en cuenta las restricciones del problema, si un vértice  $v$  se añade a la solución, entonces todos los vértices en la capa opuesta que no sean adyacentes a  $v$  no pueden ser añadidos en iteraciones futuras, ya que en dicho caso la solución obtenida no sería un biclique. Sin embargo, quitar algunos vértices con el método *Shake* puede permitir eventualmente que nuevos vértices sean añadidos a la solución

(i.e., aquellos que no eran adyacentes a ninguno de los vértices eliminados).

Por lo tanto, proponemos una etapa de reconstrucción que se ejecuta después de cada *Shake*. En concreto, la fase de reconstrucción intenta añadir nuevos vértices a la solución, aquellos que no eran candidatos factibles antes de ejecutar el método *Shake*.

La etapa de reconstrucción siempre mejora o, al menos, mantiene la calidad de la solución obtenida tras la llamada al método *Shake*. Obsérvese que la solución reconstruida solo supera a la inicial si y solo si la etapa de reconstrucción es capaz de insertar más de  $k$  vértices en cada capa.

La naturaleza aleatoria de este procedimiento hace que sea difícil obtener mejoras en la calidad de la solución. Para mitigar este efecto se proponen cuatro variantes del método *Shake*. Estas se diferencian en cómo se realizan las fases de destrucción y reconstrucción de la solución, cada fase puede ser respectivamente aleatoria (R) o voraz (G), con lo que obtenemos cuatro variantes: RR, RG, GR, GG. La Tabla I muestra el comportamiento voraz o aleatorio de cada una de las variantes propuestas. Por ejemplo, la variante de *Shake* GR realiza una destrucción voraz con una reconstrucción aleatoria.

Variante	Destrucción	Reconstrucción
RR	Aleatoria	Aleatoria
RG	Aleatoria	Voraz
GR	Voraz	Aleatoria
GG	Voraz	Voraz

Tabla I: Enumeración de las cuatro variantes de *Shake* propuestas.

En la fase de reconstrucción se utiliza el mismo método constructivo que genera la solución inicial, pero modificado para ser totalmente aleatorio ( $\alpha = 0$ ) o totalmente voraz ( $\alpha = 1$ ). En la fase de destrucción se plantea un algoritmo, con una estructura similar a la del método constructivo, que elimina vértices de una solución factible. Para que sea una destrucción voraz es necesario definir una nueva función heurística  $g'$  que puntúe los vértices a eliminar. El valor de esta función heurística para cada vértice  $v \in S$  se calculará por el número de vertices en la otra capa con los que no está conectados.

### III. RESULTADOS EXPERIMENTALES

En esta sección se presentan dos grupos de experimentos: los experimentos preliminares, realizados para ajustar los parámetros del algoritmo propuesto; y el experimento final, diseñado para evaluar la calidad de nuestra propuesta algorítmica y compararla con el algoritmo previo de la literatura. Todos los algoritmos fueron implementados en Java y se ejecutaron en un sistema con una CPU Intel i7 (7660U) y 8 GB de RAM, en la máquina virtual de Java 8.

Se ha utilizado el mismo conjunto de datos presentado en [20], facilitado por dichos autores, que consiste en 30 grafos bipartitos balanceados con tamaños  $n = \{250, 500\}$ , donde  $n$  representa el número de vértices en cada capa; y con diferentes

probabilidades  $p = \{85\%, 90\%, 95\%\}$  de que una arista exista en el grafo. Se trata de grafos densamente poblados en los que falta un porcentaje bajo de aristas para que lleguen a ser completos. Este conjunto de datos se utiliza para comparar el rendimiento de nuestro algoritmo con el estado del arte. A parte de las instancias utilizadas para presentar sus resultados, los autores de [20] también facilitan otras instancias generadas con los mismos parámetros, no utilizadas en su artículo, y que en este trabajo se utilizan para ajustar los parámetros del algoritmo.

En estos experimentos presentamos los siguientes datos: el tamaño promedio del biclique balanceado más grande obtenido para el conjunto de datos, Tamaño; el tiempo promedio de ejecución por instancia, Tiempo (s); el porcentaje de desviación promedio respecto de la mejor solución obtenido por instancia, %Desv.; y el número de veces que se encuentra la mejor solución para cada instancia, #Mejores.

#### III-A. Experimentos preliminares

Los experimentos presentados a continuación fueron diseñados para elegir la mejor variante para el algoritmo propuesto. Se utilizó un grupo reducido de 6 instancias representativas, una por cada combinación posible de parámetros, seleccionadas a partir de las excluidas del experimento final para no sobreajustar el algoritmo. Estas instancias forman parte de las facilitadas por [20] y han sido generadas al azar con los mismos parámetros  $n$  (tamaño) y  $p$  (probabilidad) que aquellas utilizadas en la comparación de resultados. En el primer experimento se comprueba cuál es el mejor valor de  $\alpha$  para el procedimiento constructivo, en el segundo se comparan cuatro variantes del procedimiento *Shake*, y finalmente se examina cuál es el valor más conveniente para la vecindad máxima a explorar. Todos los experimentos se han ejecutado iterativamente hasta alcanzar el límite de tiempo establecido, un número de segundos igual al tamaño  $n$  de la instancia.

$\alpha$	Tamaño	Tiempo (s)	%Desv.	#Mejores
0.25	46.33	375.00	11.57	0
0.50	48.33	375.00	7.96	0
0.75	52.00	375.00	0.96	2
<b>rnd</b>	<b>52.50</b>	<b>375.00</b>	<b>0.00</b>	<b>6</b>

Tabla II: Comparación del algoritmo constructivo con distintos valores del parámetro  $\alpha$ .

En el primer experimento ejecutamos iterativamente únicamente el procedimiento constructivo hasta que se alcanza el límite de tiempo para cada instancia y se guarda la mejor solución alcanzada en dicho tiempo. Se consideran los siguientes valores posibles para el parámetro alfa  $\alpha = \{0.25, 0.50, 0.75, random\}$ . En particular, el valor “random” significa que en cada iteración se elige un alfa distinto de forma aleatoria. Los resultados en la Tabla II muestran que los mejores resultados se obtienen cuando se elige aleatoriamente el parámetro alfa en cada iteración. En este caso, se obtiene un biclique balanceado de tamaño 52.50 en promedio y, además,



alcanza la mejor solución hallada en este experimento en todas las 6 instancias. Por consiguiente, tanto en los experimentos sucesivos como en el final, se utilizará este valor de alfa para el constructivo inicial que forma parte de nuestra propuesta de *RVNS*.

Shake	Tamaño	Tiempo (s)	%Desv.	#Mejores
RR	48.83	375.00	10.21	0
RG	<b>54.33</b>	375.00	0.00	6
GR	49.50	375.00	8.95	0
GG	53.17	375.00	2.37	1

Tabla III: Comparación del algoritmo *RVNS* con las cuatro variantes del método *Shake*. Se ha fijado la vecindad máxima en  $K_{max} = 50\%$ .

El siguiente experimento está diseñado para elegir la mejor variante del método *Shake*. Se ha fijado la vecindad máxima del algoritmo *RVNS* en  $K_{max} = 50\%$  y se comparan las cuatro variantes propuestas para el método *Shake*. En este experimento se observa en la Tabla III que la variante RG, es decir, destrucción aleatoria con reconstrucción voraz, alcanza los mejores resultados. Esta obtiene un biclique balanceado con un tamaño de 54.33 vértices en promedio y, además, también obtiene las 6 mejores soluciones de este experimento.

$K_{max}$	Tamaño	Tiempo (s)	%Desv.	#Mejores
10%	53.17	375.00	2.37	1
20%	53.33	375.00	1.85	2
30%	53.83	375.00	0.98	3
40%	53.83	375.00	0.87	3
50%	<b>54.33</b>	375.00	0.00	6

Tabla IV: Comparación del algoritmo *RVNS* para diferentes valores de la vecindad máxima  $K_{max}$ .

En el último experimento preliminar queremos evaluar la influencia que tiene el tamaño máximo de la vecindad  $k_{max}$  sobre el algoritmo propuesto. Se utiliza la mejor configuración hallada en los experimentos anteriores, es decir, una construcción inicial con un alfa aleatorio en cada iteración y el método *Shake* que realiza primero una destrucción aleatoria y luego una reconstrucción voraz (RG); y se ejecuta el algoritmo con diferentes tamaños para la vecindad máxima  $K_{max} = \{10\%, 20\%, 30\%, 40\%, 50\%\}$ . En este experimento se puede ver que, en general, expandir el tamaño de la vecindad permite que el algoritmo alcance mejores soluciones, disminuyendo en consecuencia la desviación. Se toma como mejor vecindad  $K_{max} = 50\%$  con la que se han obtenido los mejores resultados de este experimento.

### III-B. Experimento final

En el experimento final se presenta una comparación con el algoritmo memético [20] encontrado en la literatura previa. La comparación se realiza utilizando el mismo conjunto de 30 instancias que se han utilizado en dicho trabajo. El algoritmo *RVNS* se ejecuta por iteraciones hasta que se llega a un tiempo límite, en este caso es un tiempo en segundos igual al triple

del tamaño ( $n$ ) de las instancias. En la Tabla V se puede ver que nuestros resultados son muy cercanos al algoritmo previo respecto a la calidad de las soluciones obtenidas, está a menos de un vértice de distancia en promedio, pero tiene un tiempo de ejecución que se aproxima a la mitad del tiempo requerido por el algoritmo memético.

	Tamaño	Tiempo (s)	%Desv.	#Mejores
EA/SM	55.10	2075.11	0.04	29
RVNS	54.33	1125.00	1.71	10

Tabla V: Comparación del *RVNS* con el algoritmo evolutivo EA/SM encontrado en la literatura.

## IV. CONCLUSIONES

En este trabajo se ha propuesto el uso de la metodología *RVNS* para buscar soluciones eficientes para el MBBP. Se ha constatado que en este problema es difícil plantear una búsqueda local efectiva y debido a ello se ha elegido una variante de VNS que explora aleatoriamente una vecindad predefinida. Se ha conseguido plantear un algoritmo competitivo en calidad respecto al actual estado del arte que utiliza aproximadamente la mitad del tiempo que este, por lo que todavía es un enfoque prometedor que permite explorar en un futuro otras técnicas complementarias para mejorar estos resultados.

## REFERENCIAS

- [1] M. R. Garey and D. S. Johnson, *Computers and Intractability: A Guide to the Theory of NP-Completeness*. New York: Freeman, 1979.
- [2] D. S. Johnson, "The np-completeness column: An ongoing guide." *J. Algorithms*, vol. 13, no. 3, pp. 502–524, 1992.
- [3] N. Alon, R. A. Duke, H. Lefmann, V. Rödl, and R. Yuster, "The algorithmic aspects of the regularity lemma," *J. Algorithms*, vol. 16, no. 1, pp. 80–109, 1994.
- [4] M. Dawande, P. Keskinocak, J. M. Swaminathan, and S. Tayur, "On bipartite and multipartite clique problems," *Journal of Algorithms*, vol. 41, no. 2, pp. 388 – 403, 2001.
- [5] U. Feige and S. Kogan, "Hardness of approximation of the balanced complete bipartite subgraph problem," Tech. Rep., 2004.
- [6] Y. Cheng and G. M. Church, "Biclustering of expression data," in *Proc. of the 8th ISMB*. AAAI Press, 2000, pp. 93–103.
- [7] A. Tanay, R. Sharan, and R. Shamir, "Discovering statistically significant biclusters in gene expression data," in *ISMB*, 2002, pp. 136–144.
- [8] H. Wang, W. W. 0010, J. Yang, and P. S. Yu, "Clustering by pattern similarity in large data sets," in *SIGMOD Conference*, M. J. Franklin, B. Moon, and A. Ailamaki, Eds. ACM, 2002, pp. 394–405.
- [9] M. J. Sanderson, A. C. Driskell, R. H. Ree, O. Eulenstein, and S. Langley, "Obtaining maximal concatenated phylogenetic data sets from large sequence databases," *Molecular Biology and Evolution*, vol. 20, no. 7, pp. 1036–1042, 2003.
- [10] E. J. Chesler and M. A. Langston, "Combinatorial genetic regulatory network analysis tools for high throughput transcriptomic data," in *Systems Biology and Regulatory Genomics*, ser. Lecture Notes in Computer Science, E. Eskin, T. Ideker, B. J. Raphael, and C. T. Workman, Eds., vol. 4023. Springer, 2005, pp. 150–165.
- [11] E. J. Baker, J. J. Jay, V. M. Philip, Y. Zhang, Z. Li, R. Kirova, M. A. Langston, and E. J. Chesler, "Ontological discovery environment: A system for integrating gene–phenotype associations," *Genomics*, vol. 94, no. 6, pp. 377 – 387, 2009.
- [12] R. A. Mushlin, A. Kershenbaum, S. T. Gallagher, and T. R. Rebbeck, "A graph-theoretical approach for pattern discovery in epidemiological research." *IBM Systems Journal*, vol. 46, no. 1, pp. 135–150, 2007.



- [13] S. S. Ravi and E. L. Lloyd, "The complexity of near-optimal programmable logic array folding." *SIAM J. Comput.*, vol. 17, no. 4, pp. 696–710, 1988.
- [14] M. B. Tahoori, "Application-independent defect tolerance of reconfigurable nanoarchitectures," *JETC*, vol. 2, no. 3, pp. 197–218, 2006.
- [15] A. A. Al-Yamani, S. Ramsundar, and D. K. Pradhan, "A defect tolerance scheme for nanotechnology circuits." *IEEE Trans. on Circuits and Systems*, vol. 54-I, no. 11, pp. 2402–2409, 2007.
- [16] M. B. Tahoori, "Low-overhead defect tolerance in crossbar nanoarchitectures." *JETC*, vol. 5, no. 2, 2009.
- [17] M. Yannakakis, "Node-deletion problems on bipartite graphs." *SIAM J. Comput.*, vol. 10, no. 2, pp. 310–327, 1981.
- [18] B. Yuan and B. Li, "A low time complexity defect-tolerance algorithm for nanoelectronic crossbar," in *International Conference on Information Science and Technology*, 2011, pp. 143–148.
- [19] —, "A fast extraction algorithm for defect-free subcrossbar in nanoelectronic crossbar," *ACM Journal on Emerging Technologies in Computing Systems (JETC)*, vol. 10, no. 3, p. 25, 2014.
- [20] B. Yuan, B. Li, H. Chen, and X. Yao, "A new evolutionary algorithm with structure mutation for the maximum balanced biclique problem," *IEEE Trans. Cybernetics*, vol. 45, no. 5, pp. 1040–1053, 2015.
- [21] P. Hansen and N. Mladenović, *Variable Neighborhood Search*. Boston, MA: Springer US, 2014, pp. 313–337.
- [22] T. A. Feo and M. G. Resende, "Greedy randomized adaptive search procedures," *Journal of global optimization*, vol. 6, no. 2, pp. 109–133, 1995.



# Búsqueda de Vecindad Variable para el problema de la agrupación y recogida de pedidos online en almacenes logísticos

Sergio Gil-Borrás, Abraham Duarte, Antonio Alonso-Ayuso y Eduardo G. Pardo

**Resumen**—En este trabajo se presenta la adaptación de un algoritmo de Búsqueda de Vecindad Variable Básica al problema de agrupación y recogida de pedidos *online* en almacenes logísticos. La recogida de pedidos en almacenes se ha convertido, en la actualidad, en una importante tarea operacional como parte de la cadena de suministro. En particular, debido a los costes derivados de esta actividad se ha tornado necesario tratar de optimizar el proceso de recogida, de modo que los productos asociados a los pedidos sean entregados de forma eficiente. Existen diferentes políticas de recogida, entre las que destacan: (i) la recogida de pedidos directa, es decir, cada pedido que llega al almacén es recogido directamente por un trabajador en orden de llegada; y (ii) la recogida por lotes, en la que varios pedidos son agrupados en un mismo lote y asignados a un trabajador, para ser recogidos simultáneamente. En este trabajo se aborda una variante del problema de recogida de pedidos, basada en la política de agrupación en lotes. En concreto, la variante abordada tiene en consideración que los pedidos llegan *online* al almacén, es decir, que no están todos disponibles al comienzo del turno de recogida, sino que van llegando a medida que la jornada de trabajo avanza. La función objetivo consiste en minimizar el tiempo máximo que un pedido permanece en el sistema.

**Palabras clave**—Búsqueda de Vecindad Variable, Agrupación en lotes, Heurísticas, *Online Order Batching Problem*.

## I. INTRODUCCIÓN

En los últimos años las compras a través de Internet se han popularizado en la sociedad. Derivado de esto, ha surgido la necesidad de mejorar los procesos que se producen dentro de los almacenes logísticos, para llevar a cabo una rápida y eficaz gestión de los pedidos, así como una reducción de costes de procesamiento de los mismos. Esto ha motivado el estudio de diferentes problemas que se producen dentro de este contexto, tan demandado por empresas de distribución. Entre los problemas que surgen, se pueden encontrar, entre otros, problemas relacionados con la recepción de mercancías, su

almacenamiento y la recogida de las mismas cuando se recibe un pedido. En este último contexto, es donde se enmarca el presente trabajo. En concreto, se estudia cómo hacer eficiente la recogida de pedidos *online* que llegan al almacén. Existen diferentes variantes de este problema, en función de factores tales como: el número de personas recogiendo los pedidos simultáneamente; si los pedidos tienen o no fecha límite de entrega; e incluso en función de la estructura concreta de los almacenes considerados (varios bloques de estanterías, número de pasillos paralelos, existencia de pasillos diagonales, etc.).

El problema que se aborda aquí es el denominado “*Online Order Batching Problem*” (OOBP). Este problema consiste en determinar el orden en el que se recogen los pedidos que van llegando al almacén de manera constante, así como la ruta necesaria para recogerlos. Para ello, se conforman una serie de lotes de recogida, formados por un conjunto de pedidos, con un tamaño máximo por lote. En este caso, cada uno de los lotes será recogido por un único trabajador. El objetivo consiste en minimizar el tiempo máximo que transcurre desde que un pedido entra en el almacén hasta que este ha sido procesado para su envío. Este tiempo es comúnmente denominado “*makespan*” en la literatura asociada a los procesos industriales. El tiempo en el que un pedido está en el almacén es, en realidad, la suma de dos tiempos. Por un lado, el tiempo de procesamiento del lote (compuesto a su vez por lo que tarda en generarse el lote y por el tiempo de espera hasta que este lote pase a ser recogido). Y, por otro lado, el tiempo que se tarda en recoger todo el lote por los pasillos del almacén y llevarse a la zona de entrega. Para este último proceso, la recogida de artículos, se emplean algoritmos que establecen una ruta dentro del almacén. En concreto, en este trabajo se han repasado tres de los algoritmos heurísticos más conocidos en la literatura, como son S-Shape [1], Largest-Gap [2] y Combined [3] [4], que se repasarán detalladamente en la Sección III.

En este trabajo se han empleado almacenes con dos pasillos trasversales, uno superior y otro inferior, y un conjunto variable de pasillos paralelos que los unen, donde se colocan los productos en columnas de igual tamaño, a ambos lados de cada pasillo paralelo. El número de pasillos y las dimensiones de la sala, así como de las estanterías, varía según la instancia seleccionada. En la Fig. 1 se puede ver un ejemplo de este tipo de almacén con dos pasillos trasversales y cinco pasillos paralelos. Cada pasillo paralelo tiene nueve posiciones de recogida a cada uno de los lados, representadas por pequeños

Sergio Gil-Borrás, Universidad Politécnica de Madrid. Ctra. Valencia, Km. 7, 28031, Madrid, España, (e-mail: [sergio.gil.borras@alumnos.upm.es](mailto:sergio.gil.borras@alumnos.upm.es)).

Abraham Duarte, Universidad Rey Juan Carlos. C/Tulipán s/n, 28933, Madrid, España, (e-mail: [abraham.duarte@urjc.es](mailto:abraham.duarte@urjc.es)).

Antonio Alonso-Ayuso, Universidad Rey Juan Carlos. C/Tulipán s/n, 28933, Madrid, España, (e-mail: [antonio.alonso@urjc.es](mailto:antonio.alonso@urjc.es)).

Eduardo G. Pardo, Universidad Politécnica de Madrid. Ctra. Valencia, Km. 7, 28031, Madrid, España, (e-mail: [eduardo.pardo@upm.es](mailto:eduardo.pardo@upm.es)).

cuadrados. El almacén mostrado tiene, por lo tanto, un total de 90 posiciones de recogida. Se considera que en cada posición de recogida se almacena únicamente un posible producto. No se consideran, por lo tanto, múltiples alturas en cada posición de recogida. En el pasillo transversal inferior se sitúa, además, el depósito, que será el punto de partida para las rutas de recogida, así como el punto de entrega de los productos recogidos en cada ruta. Este depósito aparece posicionado en el centro del pasillo, si bien existen instancias en las que el depósito se encuentra en uno de los extremos del mismo.

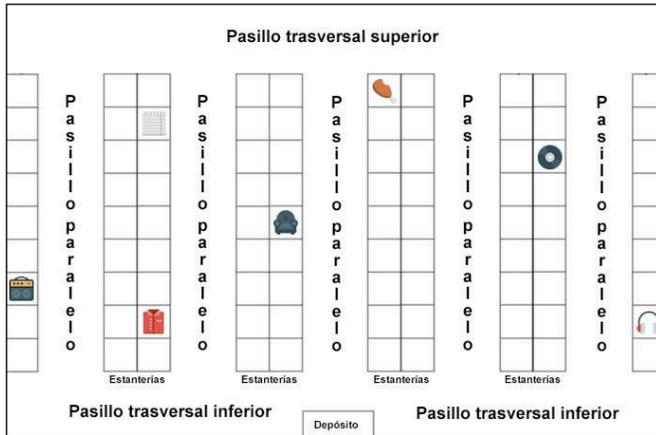


Fig. 1 – Estructura del almacén

El resto del artículo está estructurado de la siguiente forma: en la Sección II se repasa el estado del arte del problema abordado. En la Sección III se describen los algoritmos de enrutamiento más relevantes de la literatura. En la Sección IV se presentan los algoritmos heurísticos de agrupación propuestos, basados en la metodología de Búsqueda de Vecindad Variable. En la Sección V se muestran algunos resultados preliminares obtenidos y los conjuntos de instancias empleados. Por último, en la Sección VI se exponen las conclusiones de este trabajo.

## II. ESTADO DEL ARTE

Entre los últimos artículos publicados que se recogen en la literatura, relativos a esta familia de problemas de optimización, destaca el artículo de S. Henn en 2012 [5], donde los autores proponen un algoritmo basado en la metaheurística “*Iterated Local Search*” (ILS) [6] para abordar el problema. Este algoritmo está basado en el principio de búsqueda local y, en este artículo, se compara el algoritmo propuesto con las técnicas heurísticas clásicas de “*First Come, First Served*” (FCFS) y el método de “*Clarke and Wright*” (C&W) [7].

Más recientemente, en el año 2015, Ricardo Pérez-Rodríguez publicó un artículo [8] resolviendo también esta variante del problema. En este artículo, los autores proponen un algoritmo basado en la estimación continua de la distribución (denominado OBCEDA por sus siglas en inglés) que a su vez está basado en los bien conocidos Algoritmos de la Estimación de la Distribución (EDA) [9]. En este trabajo, se compara la propuesta realizada con un algoritmo genético y con un algoritmo basado en la metaheurística “*Tabu-Search*” [10]. En este caso también se usan las mismas instancias que usa

Sebastián Henn en su artículo del 2012, si bien no se realiza una comparación directa entre ambos trabajos.

Sobre otras variantes del problema, íntimamente relacionadas, destaca la publicación en estos últimos años del trabajo presentado por Rubrico en [11] donde la recogida de los pedidos se hace por múltiples trabajadores (habitualmente denominados *pickers*) en lugar de únicamente por uno, tal y como se realiza en el problema tratado en este documento. En este caso, Rubrico propone dos variaciones de un “*Incremental static scheduling scheme algorithm*”, que los autores denominan “*Steepest descent insertion*” y “*On multistage rescheduling*”. En este caso, los autores utilizan un conjunto de instancias generadas por ellos mismos, y se compara con el “*G66 Listing algorithm*”, el cual es una extensión del algoritmo “*Graham’s list scheduling algorithm*” [12]. También se realiza una comparación con el denominado “*Aspnes’93 algorithm*” [13].

Otra variante interesante del problema, publicada en 2016 [14], consiste en añadir una restricción de fecha/hora límite de entrega a cada pedido y, además, la recogida de los pedidos también se realiza con múltiples *pickers*. El algoritmo que los autores proponen es un algoritmo basado en reglas para preprocesar los pedidos antes de usar el algoritmo de agrupamiento de pedidos en lotes. Con esta estrategia, los autores consiguieron mejorar los resultados. En su caso, los algoritmos que usan para compararse son los “*Seed algorithms*” [15] y el “*Recalculation saving algorithms*” [16]. Las instancias utilizadas en este artículo siguen siendo las mismas instancias que introdujo Sebastián Henn en [5].

## III. ENRUTAMIENTO

Los algoritmos de enrutamiento son los encargados de decidir el camino que seguirá el trabajador por el almacén para recoger todos los pedidos incluidos en un mismo lote. El camino comenzará en el depósito que está marcado en las siguientes figuras como “D” (del término en inglés *depot*). El camino finaliza en el mismo depósito, una vez que se han recogido todos los elementos de un mismo lote. Al igual que otros problemas de enrutamiento, este problema de optimización ha sido ampliamente trabajado con anterioridad, existiendo en la literatura algoritmos heurísticos, metaheurísticos y exactos para esta variante concreta. No obstante, los algoritmos de enrutamiento elegidos para este trabajo, y que se repasan a continuación, son algoritmos heurísticos. Estos algoritmos, aunque generan soluciones con recorridos ligeramente más largos que los algoritmos exactos o que los algoritmos metaheurísticos, son más rápidos a la hora de computar una solución. Además, en términos generales, el recorrido que ofrecen suele ser de alta calidad y más comprensible por parte de los empleados del almacén.

En la Fig. 2 se puede ver una ilustración de la estrategia de enrutamiento denominada S-Shape, también conocida en algunas referencias como estrategia Transversal. Esta estrategia consiste en recorrer completamente todos los pasillos paralelos que contengan ítems que recoger. A excepción del último



pasillo con ítems, que dependerá de la posición del recogedor cuando deba entrar en dicho pasillo. En el caso que se acceda a él desde el pasillo transversal inferior, entonces se recorrerá el pasillo únicamente hasta llegar al último ítem a recoger del pasillo y luego, el recogedor dará media vuelta para recorrer ese mismo pasillo de vuelta hasta llegar de nuevo al pasillo transversal inferior y, posteriormente, volver al depósito para entregar las mercancías. No obstante, en el caso de que el *picker* se encuentre en el pasillo transversal superior, en el momento de entrar en el último pasillo, entonces este se recorrerá completamente, volviendo al pasillo transversal inferior, que contiene el depósito, para la entrega de mercancías. En la Fig. 2, están representados con color compacto negro los puntos de recogida de los ítems de un mismo lote.

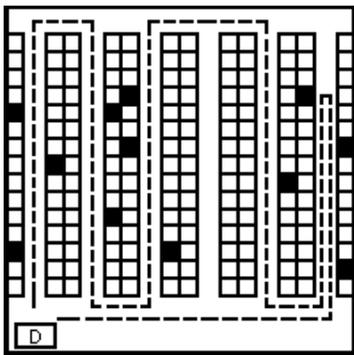


Fig. 2 – Recorrido basado en S-shape<sup>1</sup>

Análogamente, en la Fig. 2, se puede ver la estrategia de enrutamiento denominada Largest-Gap. En esta estrategia solo se recorrerán completamente el primer y último pasillo paralelo con ítems. El resto de pasillos paralelos solo se recorrerán, en el caso que tenga ítems a recoger. Además, el tramo de pasillo a recorrer será el comprendido entre el pasillo transversal del que se parta (inferior o superior según el caso) y el denominado “*largest-gap*”. Este término se utiliza para referirse al espacio más grande que hay entre cada par de ítems consecutivos en un mismo pasillo. Una vez alcanzado el *largest-gap*, el operario encargado de la recogida debe dar media vuelta sobre sus pasos y volver al pasillo transversal del que partía. En el caso de que quedasen ítems por recoger (que se encuentren más allá del *largest-gap*) estos serán recogidos en la ruta de vuelta desde el pasillo transversal contrario. Por lo tanto, desde el pasillo transversal superior se accederá solo a recoger los ítems que se encuentran en la zona situada antes del *largest-gap*, en la mitad superior de los pasillos paralelos. De manera similar, desde el pasillo transversal inferior solo se recogerán los ítems que se encuentran entre el pasillo transversal inferior y la última posición de un ítem dentro del pasillo paralelo, antes del denominado *largest-gap*.

Por último, en la Fig. 3, se puede ver la estrategia denominada Combined. En esta estrategia se combinan las técnicas de las dos estrategias anteriormente explicadas.

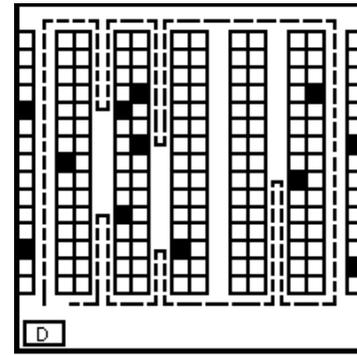


Fig. 3 – Recorrido basado en Largest Gap<sup>1</sup>

En la estrategia Combined, para recorrer cada pasillo paralelo se evalúa qué recorrido es más corto de hacer para recoger todos los ítems de un mismo pasillo, si hacer una estrategia S-Shape o si hacer una estrategia Largest-Gap. De este modo, a medida que se va avanzando se toma la mejor decisión para cada pasillo. De manera global, se puede afirmar que los resultados obtenidos con esta estrategia son mejores que aquellos obtenidos aplicando las anteriores estrategias expuestas de manera independiente. En la Fig. 4, se presenta un ejemplo de un recorrido empleando la estrategia Combined, para la misma instancia representada en la Fig. 2 y en la Fig. 3.

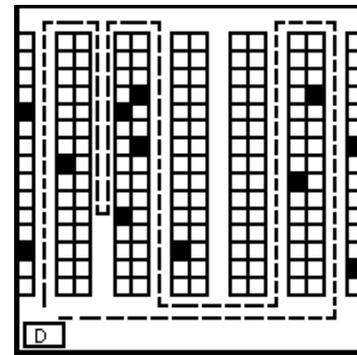


Fig. 4 – Recorrido basado en Combined<sup>1</sup>

#### IV. AGRUPAMIENTO

Para abordar el problema del agrupamiento de pedidos en lotes, se propone la combinación de dos algoritmos: un algoritmo constructivo voraz y una metaheurística, como método de mejora de la solución inicial formada por el constructivo.

El método constructivo ordena los pedidos en función del orden de llegada y parte de un lote vacío. A continuación, toma el primer pedido según el orden establecido y trata de añadirlo al último lote disponible (en el caso inicial, el lote vacío). Cuando este lote no tiene espacio suficiente crea un nuevo lote. Este proceso se repite hasta que todos los pedidos han sido asignados a un lote. En lo sucesivo se denominará a este método constructivo como *First-Come-First-Serve* (FCFS). Se propone también una variante de este método consistente en tratar de añadir el siguiente pedido en el orden establecido a cada uno de los lotes previos (no solo en el último) intentando, de ese modo, completar el espacio vacío en los lotes. A este método se le denominará en lo sucesivo como *First-Come-First-Serve Completo* (FCFS-Completo).

1. La Fig. 2, Fig. 3 y Fig. 4 han sido obtenidas de la página web de la Universidad de Rotterdam: <https://www.erim.eur.nl/material-handling-forum/research-education/tools/calc-order-picking-time/what-to-do/routing-strategies/>, el día 13 Julio de 2018.

Además de los métodos constructivos anteriormente descritos, se propone la utilización de un método basado en la metaheurística Búsqueda de Vecindad Variable (VNS) [17]. VNS es un algoritmo metaheurístico que ayuda a resolver problemas complejos tanto de optimización combinatoria como de optimización global. En concreto, partiendo de una solución inicial, intenta mejorarla visitando distintos vecindarios. Mediante la utilización de una búsqueda local explora, en cada vecindario, las posibles soluciones prometedoras, obteniendo un óptimo local en cada uno de ellos.

Existen diferentes variantes dentro de la metodología VNS. En este trabajo, se ha escogido la variante denominada "Búsqueda de Vecindad Variable Básica" (BVNS, del inglés *Basic Variable Neighborhood Search*). El algoritmo BVNS se basa en tres métodos: un método consistente en una búsqueda local para alcanzar un óptimo local en un vecindario dado; un método de perturbación de la solución y un método que determina si debe o no cambiarse la vecindad a explorar. En Algoritmo I se presenta el pseudocódigo del método BVNS.

ALGORITMO I  
FUNCIÓN BVNS

```
Función BVNS (x, k_max, t_max);
1: repeat
2:   k ← 1;
3:   repeat
4:     x' ← Shake(x, k) /* Perturbación */;
5:     x'' ← PrimeraMejora (x') /* Búsqueda local */;
6:     x ← CambioVecindad (x, x'', k)
        /* Cambio de vecindad */;
7:   until k = k_max ;
8:   t ← CpuTime()
9: until t > t_max ;
```

Cada iteración del método BVNS repite la ejecución de los tres métodos anteriormente mencionados, mientras que no se alcance el valor máximo de  $k$  (denotado por el parámetro  $k_{max}$ ), que determina el máximo número de vecindades a explorar. Una vez alcanzado el valor de  $k_{max}$ , se permite realizar una nueva exploración completa si el tiempo máximo de ejecución ( $t_{max}$ ) no se ha superado.

El método de búsqueda local propuesto dentro del algoritmo BVNS se presenta en el pseudocódigo de la función PrimeraMejora (ver Algoritmo II). Este método, dada una solución de partida  $x$  explora las soluciones en el vecindario de  $x$ , denotado como  $N(x)$ , hasta que encuentra una solución de mejor calidad, en cuyo caso, utiliza esta nueva solución como punto de partida para la siguiente iteración del algoritmo. El procedimiento se repite hasta que toda la vecindad ha sido explorada. La vecindad, en el caso de esta búsqueda local, está definida por movimientos de inserción factibles, es decir, se toma un pedido de un lote y se trata de insertar en cada uno de los otros lotes disponibles, realizando la inserción únicamente si el pedido cabe en el lote. En concreto, se realizará el primer movimiento factible que suponga una mejora en valor de la función objetivo de la nueva solución vecina. El procedimiento se repite hasta que ningún movimiento mejora la solución.

ALGORITMO II  
FUNCIÓN PRIMERA MEJORA

```
Función PrimeraMejora(x)
1: repeat
2:   x' ← x;
3:   i ← 0;
4:   repeat
5:     i ← i+1
6:     x ← argmin { f(x), f(x^i) }, x^i ∈ N(x)
7:   until ( f(x) < f(x^i) or i = |N(x)|)
8: until ( f(x) ≥ f(x'))
9: return x
```

El método encargado de realizar una perturbación de la solución (denominado Shake) se utiliza para escapar del óptimo local actual mediante el movimiento a una nueva vecindad. En este caso, el método de perturbación se basa en movimientos de intercambio de pedidos. Es decir, se toman dos pedidos de dos lotes distintos, al azar, y se intercambian, siempre y cuando al realizar el intercambio la solución continúe siendo factible (no se sobrepase la capacidad de los lotes involucrados). Este mecanismo se aplica tantas veces como indique la variable  $k$ . Por último, se incluye un mecanismo para determinar si se debe explorar una vecindad de mayor tamaño, o bien se deben explorar de nuevo vecindades próximas a la que se acaba de explorar. Este mecanismo se implementa en el método CambioVecindad, recogido en el pseudocódigo de Algoritmo III.

ALGORITMO III  
FUNCIÓN CAMBIOVECINDAD

```
Función CambioVecindad (x, x', k)
1: if f(x') < f(x) then
2:   x ← x' /* Realizar un movimiento */
3:   k ← 1 /* Volver a vecindad inicial */
4: else
5:   k ← k+1 /* Siguiendo vecindad */
```

Tal y como se ha indicado anteriormente, los pedidos no están disponibles, en su totalidad, al comienzo de la jornada de trabajo. Durante la ejecución del algoritmo los pedidos entran en el sistema siguiendo una distribución uniforme. El algoritmo BVNS se ejecuta durante un tiempo  $t_{max}$ , considerando, en cada iteración, los pedidos que hayan llegado hasta ese momento. Una vez alcanzado el valor de  $t_{max}$ , el método comienza de nuevo, realizando una nueva construcción y añadiendo los nuevos pedidos que hayan llegado durante el tiempo de la última ejecución de BVNS. En cada ejecución del algoritmo se devuelve la mejor solución encontrada. Cuando el trabajador encargado de la recogida ha terminado con un último lote, se le asigna, de la última solución disponible, uno de los lotes aún no recogidos. Para determinar qué lote será el siguiente en recogerse se emplea un algoritmo de selección. En concreto, este algoritmo, elegirá el lote que tiene un menor valor del cociente entre el tiempo estimado que tarda en recogerse el lote y el peso del mismo.



## V. RESULTADOS

En esta sección se describe el conjunto de instancias utilizadas para la validación de los algoritmos propuestos y se recogen, además, los resultados por instancia, de entre el conjunto de instancias seleccionadas.

### A. Instancias

Las instancias usadas para hacer esta investigación son las publicadas por Albareda-Sambola et al. [18], en 2009. Las instancias constan de 4 tipos de almacenes rectangulares con el depósito colocado en la esquina inferior izquierda o en el centro inferior del almacén. La distribución de los ítems en los almacenes de las instancias puede ser de dos tipos: ABC y aleatoria. Las distribuciones de tipo ABC dividen los productos en tres categorías, situando los productos más demandados en la categoría A, y los menos demandados en las categorías B y C respectivamente. Una vez clasificados los productos, aquellos que caen dentro de la categoría A se sitúan más próximos al *depot*, los pertenecientes a la categoría B, se sitúan a continuación y, por último, se almacenan los productos pertenecientes a la categoría C. Además, cada instancia tiene distinto número de pedidos (50, 100, 150, 200 y 250). Las instancias empleadas para el problema son una pequeña selección de 10 instancias de entre todas las publicadas en [18]. Es importante destacar que, en este artículo no se emplean las instancias de tamaño 50 pedidos, ya que no generan la congestión suficiente para que sistema tenga sentido. Al no producirse congestión, para este tipo de instancias basta con seguir una política de recogida *First-Come-First-Serve* (FCFS). Para hacer la experimentación presentada en este documento, las instancias, con origen en la versión *offline* del problema, han tenido que ser adaptadas a instancias aptas para la recepción de pedidos *online*, generando un sistema de entrega de paquetes que distribuya la llegada de los pedidos. En concreto, el proceso encargado de entregar los paquetes al sistema sigue una distribución uniforme y los pedidos son entregados en un horizonte temporal de 4 horas.

### B. Resultados

Por último, se ha comparado la propuesta algorítmica con los resultados obtenidos por el algoritmo del estado del arte "*Iterated Local Search*" propuesto por Henn [5] en su artículo de 2012. La comparación se ha realizado entre dicho algoritmo y dos variantes del BVNS propuesto, donde se combina un BVNS con cada uno de los dos tipos de construcciones iniciales. Un FCFS estándar y un FCFS-Completo, donde siempre se intenta completar la capacidad del lote a la llegada de cada pedido, con independencia de que dicho lote se hubiera dado por lleno en la iteración anterior. El BVNS se ejecuta en iteraciones de 60 segundos, permitiendo a los algoritmos constructivos, reconstruir la solución con los nuevos pedidos llegados al sistema antes de continuar con la búsqueda. Como selector, para determinar el siguiente lote a ser recogido, se emplea el criterio del lote que tiene un menor valor en el cociente obtenido al dividir el tiempo que tarda en recogerse el lote entre el peso del mismo.

En la Tabla I y en la Tabla II de resultados, respectivamente, se observa como la diferencia entre los resultados arrojados por los algoritmos es muy pequeña. En concreto, se reportan en la Tabla I los valores de función objetivo por instancia, obtenidos por cada método comparado y, en la Tabla II, la desviación obtenida respecto a la mejor solución del experimento. En este caso, ILS aparece como el mejor método, siendo capaz de obtener el mayor número de mejores soluciones y la menor desviación. Los mejores resultados, por cada instancia, están resaltados en negrita en las tablas.

TABLA I  
COMPARACIÓN CON EL ESTADO DEL ARTE  
TIEMPO MÁXIMO DE LOS PEDIDOS EN EL SISTEMA

Instancia	ILS	BVNS - FCFS	BVNS - FCFS Completo
A1_100_000	1721232	1666627	<b>1578027</b>
A1_100_030	<b>1215180</b>	2081531	2621530
A1_100_060	<b>1515669</b>	1945930	1885316
A1_100_090	<b>1099946</b>	1409978	1443535
A1_150_000	<b>2876411</b>	4215847	3375709
A1_150_030	<b>1081205</b>	1426639	1645529
A1_150_060	<b>2651687</b>	2855052	3770849
A1_150_090	<b>1232818</b>	1437467	1422996
A1_200_000	5578399	2273878	<b>1479272</b>

TABLA II  
COMPARACIÓN CON EL ESTADO DEL ARTE  
DESVIACIÓN RESPECTO A LA MEJOR SOLUCIÓN DEL EXPERIMENTO

Instancia	ILS	BVNS - FCFS	BVNS - FCFS Completo
A1_100_000	9,1%	5,6%	<b>0,0%</b>
A1_100_030	<b>0,0%</b>	71,3%	115,7%
A1_100_060	<b>0,0%</b>	28,4%	24,4%
A1_100_090	<b>0,0%</b>	28,2%	31,2%
A1_150_000	<b>0,0%</b>	46,6%	17,4%
A1_150_030	<b>0,0%</b>	31,9%	52,2%
A1_150_060	<b>0,0%</b>	7,7%	42,2%
A1_150_090	<b>0,0%</b>	16,6%	15,4%
A1_200_000	277,1%	53,7%	<b>0,0%</b>

En la Tabla III, se muestran los resultados obtenidos de manera resumida. En concreto, se presenta el promedio de desviación de las 10 instancias consideradas y la suma del número de veces que un algoritmo ha encontrado el mejor valor.

TABLA III  
COMPARACIÓN CON EL ESTADO DEL ARTE  
RESULTADOS AGRUPADOS

Instancia	ILS	BVNS - FCFS	BVNS - FCFS Completo
Promedio	<b>31,8%</b>	32,2%	33,2%
Número de mejores	<b>7</b>	0	2

## VI. CONCLUSIONES

En este trabajo se ha estudiado el problema de agrupación y recogida de pedidos *online* en almacenes logísticos. Este problema de optimización, consiste, por un lado, en la agrupación en lotes de los pedidos que llegan al sistema y, por otro, en el diseño de rutas eficientes para recoger cada lote. La variante abordada considera que únicamente se dispone de un

trabajador y que los pedidos llegan al almacén de manera *online*, es decir, no todos los pedidos están disponibles al comienzo de la jornada de trabajo, sino que van llegando a medida que avanza el proceso de recogida.

Para abordar el problema se ha repasado el estado del arte de la variante *online* del mismo y se han descrito los métodos de *routing* más comunes en la literatura. A continuación, se ha propuesto un algoritmo basado en la metodología de Búsqueda de Vecindad Variable, en concreto, su versión Básica. Se ha implementado también el algoritmo más destacado del estado del arte. Para validar el algoritmo propuesto se ha adaptado un subconjunto de las instancias presentes en la literatura para la versión *offline* del problema, estableciendo una distribución uniforme para la llegada de los pedidos al almacén, y se han ejecutado ambos algoritmos en la misma máquina.

Pese a ser aún un trabajo en desarrollo, los resultados obtenidos son prometedores, siendo el algoritmo propuesto competitivo con la mejor variante en el estado del arte de la actualidad. Si bien, el método del estado del arte, propuesto por Henn en 2012, es el mejor, en promedio, de los algoritmos estudiados.

Como trabajos futuros, en primer lugar, se plantea la posibilidad de mejorar el algoritmo constructivo voraz utilizado como punto de partida inicial. Además, parece recomendable probar diferentes vecindades a la propuesta en este trabajo, de modo que se puedan conformar nuevas búsquedas locales para embeber dentro del esquema de Búsqueda de Vecindad Variable Básica. De manera similar, varias búsquedas locales pueden ser utilizadas en un esquema de Búsqueda de Vecindad Variable General. Por otro lado, las estrategias más prometedoras propuestas, pueden ser empleadas también para resolver otras variantes del problema tales como: disponer de más de un trabajador para recoger los pedidos en el almacén; o establecer una fecha/hora límite de entrega de cada pedido que se debe cumplir para evitar penalizaciones.

#### AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por el Ministerio de Economía y Competitividad, Referencias “TIN2015-65460-C2-2-P y MTM2015-63710-P”.

#### REFERENCIAS

- [1] R. Hall., «Distance approximation for routing manual pickers in a warehouse», *IIE Transactions*, n° 25, pp. 77–87, 1993.
- [2] C. Petersen, «Routeing and storage policy interaction in order picking operations», *Decision Science institute Proceedings*, n° 31, pp. 1614 - 1616, 1995.
- [3] R. De Koster, E. Van der Poort y K. Roodbergen, «When to apply optimal or heuristic routing of orderpickers, in: Advances in Distribution Logistics», *Springer*, pp. 375–401, 1998.
- [4] K. Roodbergen y C. Petersen, «How to improve order picking efficiency with routing and storage policie», *Progress in Material Handling Practice*, pp. 107–124, 1999.
- [5] S. Henn, «Algorithms for On-line Order Batching in an Order- Picking Warehouse», *Computers & Operations Research*, n° 39, pp. 2549–2563, 2012.
- [6] H. R. Lourenco, O. C. Martin y T. Stutzle, «Iterated Local Search: framework and applications», *Handbook on MetaHeuristics*, pp. 363–397, 2001.
- [7] C. G. y W. J., «Scheduling of vehicles from a central depot to a number of delivery points», *Operations Research*, vol. 4, n° 12, pp. 568–581, 1964.
- [8] R. Pérez-Rodríguez, A. Hernández-Aguirre y S. Jöns, «A continuous estimation of distribution algorithm for the online order-batching problem», *Int J Adv Manuf Technol*, pp. 569–588, 2015.
- [9] P. Larrañaga y J. A. Lozano, *Estimation of Distribution Algorithms a New Tool for Evolutionary Computation*, Boston, MA: Springer, 2002.
- [10] F. Glover, «Future paths for integer programming and links to artificial intelligence», *Computers and Operations Research*, vol. 13, n° 5, pp. 533–549, 1986.
- [11] J. Rubrico, T. Higashi, H. Tamura y J. Ota, «Online rescheduling of multiple picking agents for warehouse management», *Robotics and Computer Integrated Manufacturing*, n° 27, pp. 62–71, 2011.
- [12] R. Graham, «Bounds for certain multi-processing anomalies», *Bell Syst Tech*, pp. 1563–1581, 1966.
- [13] J. Aspnes, Y. Azar, F. A., S. Plotkin y O. Waarts, «On-line load balancing with applications to machine scheduling and virtual circuit routing», *Proceedings of the 25th A C Mannual symposium on the theory of computing*, pp. 623–631, 1993.
- [14] J. Zhang, X. Wanga y K. Huang, «Integrated on-line scheduling of order batching and delivery under B2C e-commerce», *Computers & Industrial Engineering*, n° 94, pp. 280–289, 2016.
- [15] Y. C. Ho y Y. Y. Tseng, «A study on order-batching methods of order-picking in a distribution centre with two cross-aisles», *International Journal of Production Research*, vol. 44, pp. 3391–3417, 2006.
- [16] R. De Koster, E. S. Van der Poort y M. Wolters, «Efficient order batching methods in warehouses», *International Journal of Production Research*, vol. 37, pp. 1479–1504, 1999.
- [17] N. Mladenovic y P. Hansen, «Variable neighborhood search», *Computers and Operations Research*, n° 24, pp. 1097–1100, 1997.
- [18] M. Albareda-Sambola, A. Alonso-Ayuso y E. Molina, «Variable neighborhood search for order batching in a warehouse», *Asia-Pacific Journal of Operational Research*, vol. 26, n°5, pp. 655–683, 2009.



# Una metaheurística paralela para grandes problemas de optimización dinámica entera mixta, con aplicaciones en la biología computacional

David R Penas

*Departamento de Estadística, Análisis matemático y Optimización, y Instituto de Matemáticas (IMAT) Universidade de Santiago de Compostela (USC), España david.rodriguez.penas@usc.es*

David Henriques

*Instituto de Investigaciones Marinas (IIM) Consejo Superior de Investigaciones Científicas (CSIC) Vigo, España*

Patricia González

*Grupo de Arquitectura de Computadores (GAC) Universidade da Coruña (UDC) Coruña, España*

Ramón Doallo

*Grupo de Arquitectura de Computadores (GAC) Universidade da Coruña (UDC) Coruña, España*

Julio Saez-Rodriguez

*Joint Research Centre for Computational Biomedicine (JCR-Combine) RWTH Aachen University Aquisgrán, Alemania*

Julio R Banga

*Instituto de Investigaciones Marinas (IIM) Consejo Superior de Investigaciones Científicas (CSIC) Vigo, España*

**Abstract**—Esto es un resumen de nuestro artículo publicado en PLoS ONE [1] para su presentación en la Multiconferencia CAEPIA'18 Key Works.

**Index Terms**—Optimización MIDO-MINLP, programación paralela, metaheurística cooperativa, Scatter Search.

## I. INTRODUCCIÓN

Muchos problemas clave dentro de la bioinformática, la biología computacional o la biología de sistemas [2], se pueden resolver a través de formulaciones basadas en la optimización matemática. Un ejemplo es el desarrollo de modelos matemáticos dinámicos, donde se mapean comportamientos que varían en el tiempo de determinados procesos biológicos, como por ejemplo el de rutas metabólicas, o la regulación de determinados genes.

En este trabajo nos hemos centrado en los conocidos en bioinformática como problemas de ingeniería inversa [3], los cuales consisten en reconstruir la estructura de una red celular a partir de sus datos experimentales. Este proceso puede ser formulado como un problema de optimización dinámica entera mixta (MIDO), debido a las variables dependientes en el tiempo y al uso de logic-ODEs [4] para mapear ciertos comportamientos en el modelo, y donde además parte de las variables de decisión son discretas (binarias o enteras). Adicionalmente, este tipo de optimización también pertenece a la programación no lineal entera mixta (MINLP), dando lugar a problemas extremadamente difíciles de resolver debido a que presentan no linealidad, no convexidad, mal acondicionamiento y multimodalidad.

Las metaheurísticas son una buena alternativa a tener en cuenta en este contexto, ya que generalmente alcanzan una

región cercana a la solución global en un tiempo de ejecución aceptable. Sin embargo, cuando estos problemas tienen un tamaño o complejidad considerable, el costo computacional puede llegar a ser muy alto [5], [6].

Por ello, en este trabajo se ha presentado saCeSS2 [7]: una metaheurística cooperativa y auto-adaptativa con capacidad para resolver problemas MIDO-MINLP de manera satisfactoria en un tiempo de cálculo razonable.

## II. MÉTODOS

Una de las contribuciones de este trabajo es la actualización de saCeSS [8], la cual es una herramienta distribuida, cooperativa y auto-adaptativa del método de búsqueda dispersa, en concreto del enhanced Scatter Search (eSS) [9], [10]. Así, saCeSS es un optimizador global orientado a trabajar con problemas NLP que implementa las siguientes funcionalidades:

- *Paralelización a grano fino combinando el modelo maestro-esclavo con un modelo en islas:* cada esclavo/isla ejecuta de manera aislada una búsqueda con eSS, y cuando se encuentra una solución prometedora, se envía al maestro, el cual es el encargado de gestionar las comunicaciones entre las diferentes islas, evitando así un exceso de compartición de resultados que podría degradar la diversidad del método.
- *Cooperación de soluciones basado en la calidad de la solución:* el intercambio de información entre islas solo se realiza cuando una isla encuentra una solución lo suficientemente buena.
- *Comunicaciones asíncronas:* el protocolo de comunicaciones diseñado es asíncrono, para evitar retardos y

esperas, haciendo que la búsqueda de soluciones de cada isla nunca se pare.

- *Esquema autoadaptativo*: se ha implementado un mecanismo de auto-configuración de los parámetros de la metaheurística. Cada isla comenzará el proceso de optimización con unas opciones de configuración diferentes. A medida que la búsqueda avance, el maestro permitirá que los esclavos que hayan aportado menos soluciones a la búsqueda global adquieran la configuración de aquellos que hayan sido más exitosos.

Por lo tanto, la principal aportación de este trabajo es la presentación de un nuevo método, saCeSS2, que resulta de las modificaciones del método saCeSS original con el principal objetivo de resolver problemas MIDO-MINLP. Esta extensión de funcionalidades ha seguido tres direcciones principales:

- 1) *Inclusión de un solucionador local especializado en la resolución de problemas de optimización entera mixta*: se ha combinado el eSS con un método de programación cuadrática, llamado Mixed-Integer Sequential Quadratic Programming (MISQP) [11], en cada isla.
- 2) *Modificación del mecanismo de auto-adaptación con el objetivo de evitar estancamiento prematuro de la convergencia*: en este tipo de problemas de optimización, encontrar nuevas soluciones candidatas a ser compartidas no es fácil, por lo tanto se han relajado las condiciones de adaptación del método.
- 3) *Implementación de nuevos mecanismo para mantener la diversidad durante el proceso de cooperación*: se ha observado que en este tipo de problemas hay que ser muy cautos durante la compartición de soluciones, ya que una cooperación agresiva daña muy rápidamente la diversidad de la isla. Por eso, cuando se realice un cambio en los parámetros de configuración de una isla que no ha contribuido lo suficiente, se produce un reinicio aleatorio de la mayoría de soluciones de su población.

Otra de las contribuciones de este trabajo ha sido la extensión y generalización de la formulación considerada por Henriques et al [4] al adoptar un enfoque genérico del problema del control óptimo entero mixto, pero sin utilizar relajaciones o transformaciones del problema original durante su resolución.

### III. RESULTADOS

Se ha probado el método propuesto en tres casos de estudio de ingeniería inversa muy complejos relacionados con la señalización celular: (1) un problema que considera una vía de señalización sintética, con 84 variables de decisión continuas y 34 binarias; (2) un modelo dinámico de señalización en cáncer de hígado que utiliza datos de alto rendimiento, con 135 variables de decisión continuas y 109 binarias; y (3) un problema extremadamente difícil relacionado con el cáncer de mama, con 690 variables de decisión continuas y 138 binarias.

Se reportaron resultados computacionales obtenidos en diferentes infraestructuras, incluyendo un clúster local, un

gran superordenador y una plataforma de Cloud pública. Curiosamente, los resultados muestran cómo la cooperación de búsquedas paralelas individuales modifica las propiedades sistémicas del algoritmo secuencial, logrando aceleraciones superlineales en comparación con una búsqueda individual (por ejemplo, aceleraciones de 15 con 10 núcleos) y mejorando significativamente (por encima del 60%) el rendimiento con respecto a un esquema paralelo no cooperativo. La escalabilidad del método también es buena (las pruebas se realizaron usando hasta 300 núcleos). Adicionalmente, se ha obtenido que la utilización de saCeSS2 en una infraestructura pública de Cloud tiene un buen rendimiento en configuraciones que usan 10 núcleos, pero el rendimiento se degrada considerablemente cuando se trata de utilizar más procesadores.

### IV. CONCLUSIONES

Los resultados mostrados en este trabajo demuestran que saCeSS2 puede ser útil en los problemas de ingeniería inversa en modelos dinámicos de complejas rutas biológicas. Además, los éxitos obtenidos mediante esta herramienta pueden ser fácilmente exportados a otros casos de estudios que también generen problemas de optimización MIDO-MINLP a gran escala, como por ejemplo la ingeniería metabólica, la biología sintética, o la programación de fármacos.

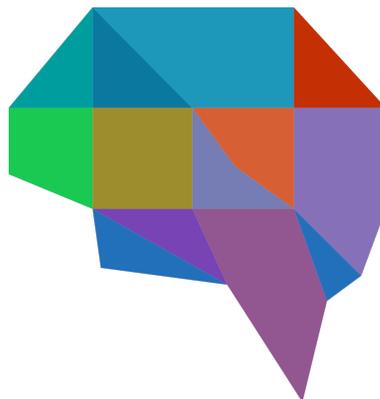
Por otro lado, desde el punto de vista computacional, también se han demostrado que las estrategias de virtualización y computación en Cloud, pueden ser una buena alternativa, aunque presentan unas bien conocidas limitaciones debido principalmente a sobrecargas en la compartición de recursos.

### REFERENCES

- [1] D.R. Penas, D. Henriques, P. González, R. Doallo, J. Saez-Rodriguez and J.R. Banga, "A parallel metaheuristic for large mixed-integer dynamic optimization problems, with applications in computational biology" *PLoS ONE*, 12(8): e0182186, 2017.
- [2] J.R. Banga, "Optimization in computational systems biology" *BMC Systems Biology*, 2 (1), 47, 2008.
- [3] A.F. Villaverde and J.R. Banga, "Reverse engineering and identification in systems biology: strategies, perspectives and challenges" *Journal of The Royal Society Interface*, 11(91), 20130505, 2014.
- [4] D. Henriques, A.F. Villaverde, M. Rocha, J. Saez-Rodriguez, J.R. Banga "Data-driven reverse engineering of signaling pathways using ensembles of dynamic models" *PLoS Computational Biology*, 13(2), e1005379, 2017.
- [5] P. Mendes and D. Kell "Non-linear optimization of biochemical pathways: applications to metabolic engineering and parameter estimation", *Bioinformatics*, 14 (10), 869–883, 1998.
- [6] C.G. Moles, P. Mendes and J.R. Banga, "Parameter estimation in biochemical pathways: a comparison of global optimization methods", *Genome Research*, 13 (11), 2467–2474, 2003.
- [7] saCeSS2 - global mixed-integer optimization library version 2017A, <https://zenodo.org/record/290219>
- [8] D.R. Penas, P. González, J.A. Egea, R. Doallo and J.R. Banga "Parameter estimation in large-scale systems biology models: a parallel and self-adaptive cooperative strategy", *BMC Bioinformatics*, 18:52, 2017.
- [9] J.A. Egea, R. Martí, J.R. Banga, "An evolutionary method for complex-process optimization", *Computers & Operations Research*, 37(2), 315–324, 2010.
- [10] J.A. Egea, E. Balsa-Canto, M.S. G. García, J.R. Banga, "Dynamic optimization of nonlinear processes with an enhanced scatter search method", *Industrial & Engineering Chemistry Research*, 48(9), 4388–4401, 2009.
- [11] O. Exler, K. Schittkowski, "A trust region sqp algorithm for mixed-integer nonlinear programming", *Optimization Letters*, 1(3), 269–280, 2007.

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 3: HEURÍSTICAS,  
HIPERHEURÍSTICAS Y  
METAHEURÍSTICAS







# Genetic programming to evolve priority rules for on-line scheduling on single machine with variable capacity

Francisco Gil-Gala, Carlos Mencía, María R. Sierra, Ramiro Varela

*Department of Computer Science, University of Oviedo,*

*Campus of Gijón, Gijón 33204, Spain*

{giljavier, menciacarlos, sierramaria, ramiro}@uniovi.es

<http://www.di.uniovi.es/iscop>

**Abstract**—On-line scheduling is often required in a number of real-life settings. This is the case of distributing charging times for a large fleet of electric vehicles arriving stochastically to a charging station under power constraints. In this paper, we consider a scheduling problem derived from a situation of this type: one machine scheduling with variable capacity and tardiness minimization, denoted  $(1, Cap(t) || \sum T_i)$ . The goal is to develop new priority rules to improve the results from some classical ones as Earliest Due Date (EDD) or Apparent Tardiness Cost (ATC). To this end, we developed a Genetic Programming (GP) approach. We conducted an experimental study showing that it is possible to evolve new efficient rules that outperform ATC and EDD using the same problem attributes and operations.

**Index Terms**—Scheduling, One machine scheduling, Priority Rules, Genetic Programming, Hyperheuristics, Electric Vehicle Charging Scheduling

## I. INTRODUCTION

One machine scheduling problems have attracted an ever increasing body of research over the last decades, due to both their usual high computational complexity as well as for acting as building blocks in the development of solutions to more complex scheduling problems. This paper focuses on a problem in this class in which a number of jobs must be scheduled on a single machine, whose capacity varies over time, with the objective of minimizing the *total tardiness* objective function. This problem was introduced in [6] in the context of scheduling the charging times of a large fleet of Electric Vehicles (EVs), and it is denoted  $(1, Cap(t) || \sum T_i)$ .

Solving the Electric Vehicle Charging Scheduling Problem (EVCSP) tackled in [6] amounts to solving a number of instances of the  $(1, Cap(t) || \sum T_i)$  problem. Due to the computational intractability of this problem and the tight real-time requirements of the EVCSP, *on-line scheduling* represents the most (if not the only) suitable approach to the  $(1, Cap(t) || \sum T_i)$  problem. In [6], it is solved by means of the *Apparent Tardiness Cost* (ATC) priority rule, commonly used in the context of scheduling with tardiness objectives.

The aim of this paper is the automated development of new, efficient, priority rules specifically adapted to address the  $(1, Cap(t) || \sum T_i)$  problem. A natural way to cope with

this task is the use of hyper-heuristics, as search needs to be conducted in a space of heuristics rather than in a space of solutions to the scheduling problem. Since priority rules are arithmetic expressions that can be naturally represented by trees, we opted to investigate a Genetic Programming (GP) approach, which is proposed in this paper. Experimental results indicate that GP is capable of evolving effective priority rules for the  $(1, Cap(t) || \sum T_i)$  problem, outperforming ATC and other classical priority rules. The results also provide insights of practical interest that motivate further research.

The remainder of the paper is organized as follows. Section II reviews some GP approaches to evolve priority rules for scheduling problems. In Section III, we describe the EVCSP and show how the solving procedure proposed in [6] decomposes an instance of this problem into a number of instances of the  $(1, Cap(t) || \sum T_i)$  problem. In Section IV, we give the formal definition of the  $(1, Cap(t) || \sum T_i)$  problem. Section V introduces a schedule builder for this problem and describes its main properties. In Section VI, we present some classical priority rules used to solve the problem. Section VII describes the GP approach propose to evolve new priority rules. In Section VIII, we report the results of the experimental study conducted to evaluate the proposed GP approach. Finally, in Section IX we summarize the main conclusions and outline some ideas for future work.

## II. EVOLVING PRIORITY RULES FOR SCHEDULING PROBLEMS

The terms *Dispatching Rule* (DR) and *Priority Rule* (PR) are commonly used in the scheduling literature to refer to “a simple heuristic that derives a priority index of a job from its attributes” [1]. Due to their low computational cost, PRs are well suited for *on-line scheduling*: the job with the highest priority among those available at a given time is scheduled next. In this section, we review some existing GP approaches proposed to discovering dispatching or priority rules for scheduling problems, such as job shop (JSSP), one machine or unrelated parallel machines scheduling problems, among others. In some cases, the purpose is just to find a *good* priority rule which is then embodied into a schedule builder.

Other works notice that a single rule may not suffice and focus on finding sets of rules to be applied collaboratively to solve instances with different characteristics.

Branke, Schols-Reiter and Hildeblant analyze in [1] three representation models for priority rules for the dynamic JSSP: expression trees commonly used in GP, Artificial Neural Networks (ANNs) and weighted linear combination of job properties. Their results show that expression trees evolved by GP perform slightly better than the other approaches.

In [5], the authors propose evolving sets of rules that are used collaboratively to solve problems. They use GP to evolve a set of PRs for the static JSSP. They consider single and composite dispatching rules as terminal nodes, as for example SPT or ATC, in addition to some parameters. The rules are used in combination with various schedule builders, as for example the well-known Giffler and Thompson algorithm [4]. These rules are sequenced into heuristics. To produce a solution to the problem, each rule in the heuristic is applied in turn to schedule a single operation.

In [8], the authors consider composite PRs for the JSSP given by linear combinations of 16 problem features, as for example total remaining work for a job or total idle time for all machines. The weights in the linear function are learned from a set of optimal solutions obtained by a MILP solver. Preference and imitation learning were used for this purpose.

In [13], GP is used to learn DRs for the Order Acceptance and Scheduling problem (OAS) directly from optimal scheduling decisions. Instead of evolving just a single rule, a set of rules is evolved that is used in a Forward Construction Heuristic (FCH): at each step the rule that produces the best local improvement is applied. One of the novelties of this model is that the fitness of a rule depends on how well the rule performs at each decision point (i.e., whether or not it takes the optimal decision) rather than the final objective values of the schedule.

In [3], the authors consider on-line scheduling for multiple unrelated parallel machines. They also propose evolving new priority rules with GP, incorporating some enhancements as dimension awareness to guarantee semantically correct rules and some GP variant as gene expression.

In [2], PRs are evolved by GP for the Resource Constrained Project Scheduling Problem (RCPSP) that outperform many of the existing ones for this problem.

### III. WHERE THE $(1, Cap(t) || \sum T_i)$ PROBLEM COMES FROM

As pointed out, the  $(1, Cap(t) || \sum T_i)$  comes from the EV Charging Scheduling Problem (EVCSP) considered in [6]. In turn, the EVCSP is motivated by the charging station designed in [15] to be installed in a community park where each user has its own space. Figure 1 shows the general structure and the main components of this charging station. Each space has a charging point which is connected to one of the three lines of a three phase feeder. The system is controlled by a central server and a number of masters and slaves. Each slave takes control of two charging points and each master controls up to eight slaves in the same line. The control system registers

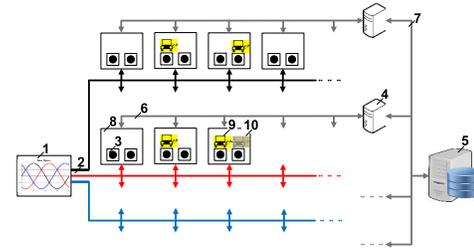


Fig. 1. General structure of the charging station. (1) Three-phase electric power 400v AC, (2) lines, (3) charging points Type 2/AC IEC 62196-2 with V2G communication interface ISO 15118, (4) masters, (5) server, (6) communication Rs 485, (7) communication TCP/IP, (8) slaves, (9) active vehicles, (10) inactive vehicles.

events as EVs arrivals and sends activation/deactivation signals to the charging points in accordance with a schedule.

Due to the EVs arrivals being not known in advance, the EVCSP is dynamic and so schedules must be computed at different points over time. Furthermore, the physical characteristics and the operating mode of the charging station impose some restrictions to the EVCSP that make it hard to solve. In particular, the contracted power is limited and so there is a maximum load in each line. Besides, the load in the three lines must be similar to avoid an excessive imbalance among the three phases. Here, we assume two simplifications of the model: (1) the contracted power is constant over time, and (2) the EVs charge at constant rate in the so called Mode 1 in accordance with the regulation UNE-EN 61851-1 [7]. Therefore, there is a maximum number  $N$  of EVs that can be charging in each line simultaneously.

Figure 2 shows a feasible schedule for the situation represented in Figure 1; dark bars represent the EVs that are charging at time  $T_k$  and light bars represent EVs that are scheduled at a later time. In this example, we consider that the maximum number of active EVs in a line is 4 and that the maximum difference in the number of active EVs in every two lines is 2. For these reasons, none of the tasks 12 and 13 can be scheduled at  $T_k$  because if some of them were scheduled at  $T_k$ , lines 2 and 3 would be imbalanced after completion of task 8, as there would be 4 EVs charging in line 2 and only one (number 9) charging in line 3, so exceeding the maximum difference of 2. The schedule built at  $T_k$  allows the EVs in the system to complete their charging periods without violating the constraints of the system. However, if new EVs arrive the charging station after  $T_k$ , a new schedule must be built to accommodate them.

To solve the EVCSP, in [6] the authors proposed an algorithm that considers at each scheduling time  $T_k$  the active EVs in each line (which cannot be rescheduled), the demanding EVs (which have not yet started to charge), the maximum number of active EVs in a line,  $N$ , and a profile of maximum load in each line  $N_i^{max}(t)$ ,  $i = 1, 2, 3$ , which is iteratively adapted to keep the imbalance among the lines under control. The objective is to schedule all the EVs in the three lines such that all the constraints are satisfied and the total tardiness, i.e., the delay w.r.t. to the times the users want to take their

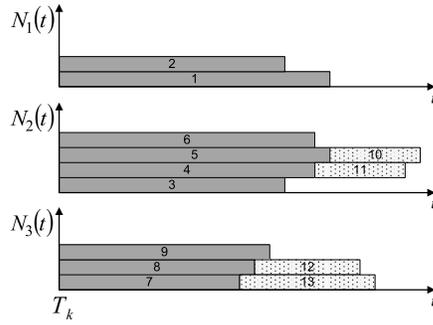


Fig. 2. A feasible schedule for the problem in Figure 1. Tasks 1 - 10 are the active EVs at time  $T_k$  in the lines 1, 2 and 3 respectively, while tasks 10 - 13 correspond to inactive EVs in the lines 2 and 3, which could be rescheduled if it were necessary to accommodate new EVs arriving after  $T_k$ .

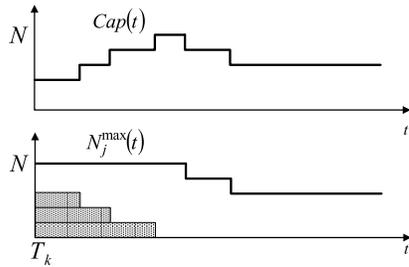


Fig. 3. Definition of the capacity of the machine  $Cap(t)$  from the maximum profile  $N_j^{max}(t)$  and the active EVs at time  $T_k$ .

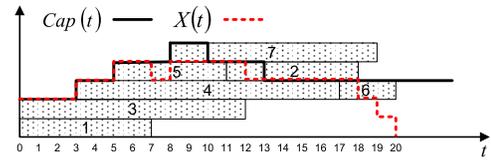
EVs away, is minimized. If two of the obtained schedules are imbalanced at some time point, some of the maximum profiles  $N_i(t)$  must be recalculated and a new schedule obtained for the line  $i$ . The details of this process are given in [6].

Therefore, scheduling the EVs in each line, subject to the maximum load and taking into account the active EVs, may be viewed as the problem of scheduling a set of jobs on a machine with variable capacity over time. The calculation of the capacity of the machine from the active EVs and the maximum load profile is illustrated in Figure 3. In this example, we consider that at the scheduling time  $T_k$  there are three EVs charging in line  $j$  as they were scheduled before  $T_k$ , and that the maximum load of line  $j$ ,  $N_j^{max}(t)$ , undergone two adjustments due to lower load in the other two lines. So, the capacity to accommodate new charging EVs,  $Cap(t)$ , for  $t \geq T_k$ , is variable as shown in the upper part of the figure.

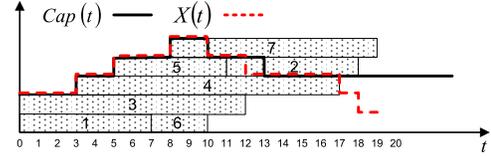
#### IV. PROBLEM DEFINITION

The  $(1, Cap(t) || \sum T_i)$  problem may be defined as follows. We are given a number of  $n$  jobs  $\{1, \dots, n\}$ , all of them available at time  $t = 0$ , which have to be scheduled on a machine whose capacity varies over time, such that  $Cap(t) \geq 0$ ,  $t \geq 0$ , is the capacity of the machine in the interval  $[t, t+1)$ . Job  $i$  has duration  $p_i$  and due date  $d_i$ . The goal is to allocate starting times  $st_i$ ,  $1 \leq i \leq n$  to the jobs on the machine such that the following constraints are satisfied:

- i. At any time  $t \geq 0$  the number of jobs that are processed in parallel on the machine,  $X(t)$ , cannot exceed the



(a) Non left-shifted schedule



(b) Left-shifted schedule

Fig. 4. Two feasible schedules for an instance of the  $(1, Cap(t) || \sum T_i)$  problem with 7 jobs and a machine with capacity varying between 2 and 5.

capacity of the machine; i.e.,

$$X(t) \leq Cap(t). \quad (1)$$

- ii. The processing of jobs on the machine cannot be preempted; i.e.,

$$C_i = st_i + p_i, \quad (2)$$

where  $C_i$  is the completion time of job  $i$ .

The objective function is the total tardiness, defined as:

$$\sum_{i=1, \dots, n} \max(0, C_i - d_i) \quad (3)$$

which should be minimized.

Figure 4 shows an example of two feasible schedules for a problem with 7 jobs; the capacity of the machine varies between 2 and 5 over time. Due dates are not represented for the sake of clarity. As we can observe, in both schedules  $X(t) \leq Cap(t)$  for all  $t \geq 0$ .

One particular case of this problem is when the capacity of the machine is constant over time. This is the parallel identical machines problem [10], denoted  $(P || \sum T_i)$ , which is NP-hard. Thus, it follows that the  $(1, Cap(t) || \sum T_i)$  problem is NP-hard as well.

#### V. SCHEDULE BUILDER

Schedule builders constitute an essential component for designing efficient scheduling algorithms. Also known as *schedule generation schemes*, these methods provide a way for computing and enumerating a subset of the feasible schedules, thus enabling the definition of a search space to look for solutions to the problem. We use here the schedule builder proposed in [12], which produces *left-shifted schedules*, in which no job can be scheduled earlier without changing the starting time of some other job. Figure 4 shows two feasible schedules for a problem instance with 7 jobs, one is not left-shifted (a), while the other one is left-shifted (b).

The schedule builder is depicted in Algorithm 1; it maintains a set  $US$  with the unscheduled jobs, as well as the consumed capacity  $X(t)$  due to the jobs scheduled so far.  $US$  is initialized with all the jobs. In each iteration, the algorithm

**Algorithm 1** Schedule Builder

---

**Data:** A  $(1, Cap(t) || \sum T_i)$  problem instance  $\mathcal{P}$ .  
**Result:** A feasible schedule  $S$  for  $\mathcal{P}$ .  
 $US \leftarrow \{1, 2, \dots, n\}$ ;  
 $X(t) \leftarrow 0; \forall t \geq 0$ ;  
**while**  $US \neq \emptyset$  **do**  
      $\gamma(\alpha) = \min\{t' | \exists u \in US; X(t) < Cap(t), t' \leq t < t' + p_u\}$ ;  
      $US^* = \{u \in US | X(t) < Cap(t), \gamma(\alpha) \leq t < \gamma(\alpha) + p_u\}$ ;  
     Non-deterministically pick job  $u \in US^*$ ;  
     Assign  $st_u = \gamma(\alpha)$ ;  
     Update  $X(t) \leftarrow X(t) + 1; \forall t$  with  $st_u \leq t < st_u + p_u$ ;  
      $US \leftarrow US - \{u\}$ ;  
**end**  
**return** The schedule  $S = (st_1, st_2, \dots, st_n)$ ;

---

selects one unscheduled job among the ones that can start at the earliest time  $\gamma(\alpha)$ .

Note that the selection of a job to be scheduled at each iteration is non-deterministic. Regardless of this, we can guarantee that the application of Algorithm 1 always results in a feasible left-shifted schedule; for example, the sequence of choices (1, 3, 4, 5, 6, 7, 2) would lead to building the schedule in Figure 4(b). Furthermore, any left-shifted schedule may be obtained considering the appropriate choice in each iteration. In other words, the scheduler searches in the whole space of left-shifted schedules, which is *dominant*; i.e., it contains at least one optimal schedule.

The schedule builder may be instantiated by using any priority rule or heuristic, as we will see in the next section. In [12] it was embedded as a decoder in a genetic algorithm.

 VI. PRIORITY RULES FOR THE  $(1, Cap(t) || \sum T_i)$ 

A schedule builder, as the one shown in Algorithm 1, may be used in combination with some priority rule to make the non-deterministic choice in each iteration: the job having the highest priority is chosen to be scheduled. This paradigm is called *priority scheduling*, which is particularly appropriate for *on-line scheduling*, where decisions must be made quickly. In the literature there are a number of rules that could be adapted to the  $(1, Cap(t) || \sum T_i)$  problem. Among the simplest ones, we may consider *Earliest Due Date* (EDD) or *Shortest Processing Time* (SPT); the first one picks the operation with the smallest due date, while SPT selects the one with the least duration. These two rules are often used for objective functions that are non decreasing with the completion time of the jobs, as for example the makespan, the lateness or even the tardiness. As they are quite simple rules, it often happens that they produce rather moderate results. In contrast, more sophisticated rules are usually able to produce (much) better results as they take into account more knowledge on the problem. This is the case of the *Apparent Tardiness Cost* (ATC) rule, which was used with success to solve some scheduling problems with tardiness objectives (e.g. [14], [9]); with this rule, the priority of each job  $j \in US$  is give by Equation (4).

$$\pi_j = \frac{1}{p_j} \exp \left[ \frac{-\max(0, d_j - \gamma(\alpha) - p_j)}{g\bar{p}} \right] \quad (4)$$

 TABLE I  
 SUMMARY OF RESULTS FROM [12]. AVERAGE TOTAL TARDINESS.

n	EDD	SPT	ATC				GA		
			0.25	0.5	0.75	1.0	Best	Avg	Time(s)
15	8.28	14.03	7.35	7.17	7.27	7.50	6.53	6.53	13.13
30	26.56	55.84	19.36	18.93	18.81	19.09	17.73	17.76	21.49
45	46.52	137.74	36.25	36.20	35.83	36.75	33.31	33.45	30.22
60	131.31	262.54	90.59	89.86	89.03	89.23	86.84	87.19	38.48
Avg	53.17	117.93	38.39	38.04	37.74	38.14	36.10	36.23	25.83

In Equation (4),  $\bar{p}$  is the average processing time of the jobs in  $US$  and  $g$  is a look-ahead parameter to be introduced by the user. As we can see, the ATC rule combines the information exploited by SPT and EDD as the priority of a job  $i$  is in inverse ratio with its duration  $p_i$  and it is decreasing with the slack time to its due date  $d_j - \gamma(\alpha) - p_j$ .

Table I reproduces some results reported in [12] obtained by the rules EDD, SPT and ATC with four values of the parameter  $g$ , and by a genetic algorithm proposed therein (GA), over a set of 120 instances distributed in four sets having different number of jobs (15, 30, 45, 60) with 30 instances each. As we can see, ATC produces much better results than both EDD and SPT, the results of the latter being actually poor, as can be expected due to the fact that this rule does not consider any information related to the tardiness objective. Besides, the performance of ATC depends on the value of the parameter  $g$ ; the best value of  $g$  depending on the the size of the instances  $n$ . Furthermore, the ATC rule produces worse results than the GA, which of course takes much longer time than the priority rules. These facts lead us to formulate the following hypotheses:

- 1) The ATC rule may be outperformed by new rules having a different structure or more detailed information of the problem domain, or just considering other parameters.
- 2) Given a benchmark containing instances with a similar structure, there may exist priority rules that are well adapted to this particular benchmark.

## VII. EVOLVING NEW PRIORITY RULES WITH GENETIC PROGRAMMING

From the hypotheses above, our purpose is to devise new dispatching rules for the  $(1, Cap(t) || \sum T_i)$  problem. To this end, we propose using hyper-heuristics, as they provide a natural way of searching over a (sub)space of the heuristics that solve a given problem. As we are interested in devising some arithmetic expression, as that of the ATC rule given in Equation (4), Genetic Programming (GP) [11] is a good choice as it provides a way of evolving tree structures.

The first step in the design of a GP solution is selecting the sets of terminal and function nodes of the candidate trees. Terminal symbols represent the elementary properties that are considered relevant to establish jobs' priorities as, for example, processing times, due dates, etc., as well as some constants. Function symbols are the elementary arithmetic operations and some other unary and binary functions.

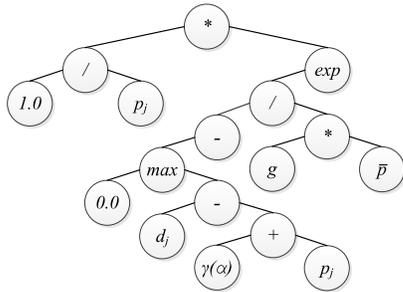


Fig. 5. Tree representing the ATC rule.

Looking at conventional rules as ATC, EDD or SPT, we have chosen the functional and terminal sets of symbols showed in Table II. The considered grammar generates any feasible expression in accordance with the arithmetic rules, without any other restrictions. For this reason, we could have inconsistencies as division by 0. To dealing with that, we make use of the EDD rule in the following way: when a rule produces a division by 0 for some job, we assume that this rule does not decide anything for that job. Then, we consider the job having the largest priority together with all jobs for which the rule did not decide and apply to these jobs the EDD rule. This way, a rule producing many divisions by 0 gets penalized as many decisions are taken by using EDD. Figure 5 shows the tree representing the ATC rule.

We remark that the set of terminal symbols only include information regarding jobs, but no information about the machine, such as its capacity  $Cap(t)$ , which is relevant in this problem. The main reason to not include it is that in a first stage we plan to analyze the extent to which it is possible to improve the conventional rules without considering new information. Besides, including new terminal symbols augments the size of the search space.

TABLE II  
FUNCTIONAL AND TERMINAL SETS USED TO BUILD EXPRESSION TREES.  
SYMBOL “-” IS CONSIDERED IN UNARY AND BINARY VERSIONS.

Function	-	+	/	*	pow	max	min	exp
Terminal	$p_i$	$d_i$	$\gamma(\alpha)$	$\bar{p}$	0.00	0.01	...	0.99 1.0

We used a rather conventional GP as proposed in [11] with only some small changes.

The evaluation of chromosomes is the most time consuming component of the algorithm and consists in solving a battery of instances of the  $(1, Cap(t) || \sum T_i)$  problem. The fitness of each individual being the inverse of the average cost (total tardiness) of the solutions obtained. Therefore, if the instances had a similar structure, for example if their data were generated from the same probability distributions, we could expect the GP to evolve rules well adapted to those instances.

The evolutionary schema used in our approach is generational, with a selection phase in which all chromosomes are organized into pairs and tournament replacement is done between every two parents and their two offsprings. The strategy is combined with elitism.

TABLE III  
GP PARAMETERS’ SETTING.

Cross., Mut., Init. pop. gen.	Standard [11]
Cross. and Mutation ratio	0.8 and 0.02 resp.
Population size	500
Number of generations	500
Max. init. chrom. depth	6
Max. chromosome size	32
Elitism	1
Number of runs	30

To control the size of chromosomes, we limit the size of the initial candidate solutions and also after crossover. In this case, if an offspring exceeded the size limit, it is discarded and the parents are mated again choosing different points until some valid offspring is reached.

## VIII. EXPERIMENTAL STUDY

We have conducted an experimental study aimed at assessing the quality of the rules obtained by the proposed approach (GP). To this aim, we implemented a prototype in Java, and ran a series of experiments on a Linux cluster (Intel Xeon 2.26 GHz. 128 GB RAM).

The experiments were carried out over a benchmark set of 2000 instances, generated by means of the procedure introduced in [12]. Each instance is characterized by the number of jobs ( $n$ ) and the maximum capacity of the machine ( $MC$ ). Given fixed  $n$  and  $MC$ , a random instance is generated using uniform distributions as follows (all sampled values are integers):

- 1) Each job  $i \in \mathcal{J} = \{1, \dots, n\}$  is assigned a random processing time  $p_i \in \{1, \dots, 100\}$ .
- 2) Once all jobs have a processing time, they are assigned a random due date  $d_i \in [p_i, \max(p_i + 2, \sum_{j \in \mathcal{J}} p_j / 2)]$ .
- 3) The capacity of the machine ( $Cap(t)$ ) is generated as a unimodal function, with each constant interval taking a random duration in the range  $[1, \sum p_j / MC]$ . Both the initial and the final capacity of the machine is a random integer in  $\{1, 2\}$ .

This procedure aims at avoiding the generation of under-constrained instances, which can be easily solved. All the 2000 instances considered in this experimental study have been generated with  $n = 60$  and  $MC = 10$ .

We ran GP considering a training subset of 50 instances to evaluate each candidate solution and used the remaining 1950 instances for testing. The parameters of GP are given in Table III. These parameters were chosen from a large set of preliminary experiments. In these experiments we ran GP 30 times and recorded the best priority rule evolved in each run. Then, we report the average results of the 30 rules and the results from the best and worst rules (over the training and test sets). These results are summarized in Table IV, which includes the results from EDD, ATC (with  $g \in \{0.25, 0.5, 0.75, 1.0\}$ ) and the solutions by the genetic algorithm from [12] (GA).

The results over the test set show that the best priority rule obtained in the training phase (which in this case is the second

TABLE IV

SUMMARY OF RESULTS. AVERAGE VALUES OF THE TOTAL TARDINESS OBTAINED FOR THE TRAINING AND TEST SETS BY THE BEST RULES EVOLVED IN EACH ONE OF THE 30 RUNS OF GP, ATC, EDD AND GA.

Priority Rules	Train.	Test.
Best(in training)	636.0	548.0
Average(30 rules)	640.4	553.1
Worst(in training)	678.0	580.0
ATC( $g=0.25$ )	660.2	565.0
ATC( $g=0.50$ )	650.9	552.8
ATC( $g=0.75$ )	650.0	557.1
ATC( $g=1.00$ )	659.0	570.2
ATC(avg. 4 $g$ -values)	655.0	561.3
EDD	833.3	695.7
GA	616.1	520.4

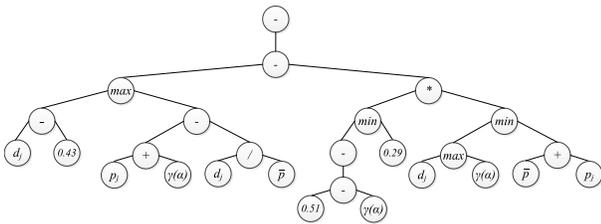


Fig. 6. Tree representing the best rule obtained.

best performing rule on the test set) performs better than the four versions of the ATC rule. In addition, the average value of the 30 evolved rules outperforms the average value of the four ATC rules. We conducted Wilcoxon paired tests confirming statistically significant differences in favor of the new best and average results obtained by the proposed GP approach. The worst performing rule evolved by GP lags behind the ATC rules, although it yields better average total tardiness than the EDD rule, which performs worst overall. The GA produces the best results, at the expense of taking much longer time (note that priority rules take negligible time).

A close look at the actual priority rules generated reveal some interesting insights. Figure 6 shows the tree representation of the best priority rule obtained in the experiments. Interestingly, we can observe that this rule contains some odd expressions, such as  $(d_j - 0.43)$  on the left-most part of the tree. This may be due to using a grammar allowing for any valid arithmetic expression, and motivates further research, e.g., using a restricted grammar instead to deal with these situations.

## IX. CONCLUSIONS

This paper studies the one machine scheduling problem with variable capacity, denoted  $(1, Cap(t) || \sum T_i)$ , and shows that Genetic Programming is a suitable approach to generate new priority rules, improving the best-performing classical ones for total tardiness minimization such as EDD and ATC. In order to make a fair comparison, we considered the same problem attributes and operations as in these rules. At the same time, we have seen that there is still room for improvement, as a genetic algorithm running for much longer time than

a schedule builder guided by priority rules is able to obtain even better solutions. Therefore, we conjecture that by using more attributes of the problem, in particular some related to the capacity of the machine, better rules may be evolved. Besides, it seems clear that no single rule can be the best one in every problem instance. Therefore, it may be more appropriate to try to evolve sets of rules to cover different subsets of instances, or to take decisions at different stages in the schedule construction. These are some promising lines of research we plan to explore in the future.

## ACKNOWLEDGEMENTS

This research has been supported by the Spanish Government under research project TIN2016-79190-R.

## REFERENCES

- [1] Branke, J., Hildebrandt, T., Scholz-Reiter, B.: Hyper-heuristic evolution of dispatching rules: A comparison of rule representations. *Evolutionary Computation* 23(2), 249–277 (2015)
- [2] Chand, S., Huynh, Q., Singh, H., Ray, T., Wagner, M.: On the use of genetic programming to evolve priority rules for resource constrained project scheduling problems. *Information Sciences* 432, 146 – 163 (2018)
- [3] Durasevic, M., Jakobovi, D., Kneevi, K.: Adaptive scheduling on unrelated machines with genetic programming. *Applied Soft Computing* 48, 419 – 430 (2016)
- [4] Giffler, B., Thompson, G.L.: Algorithms for solving production scheduling problems. *Operations Research* 8, 487–503 (1960)
- [5] Hart, E., Sim, K.: A hyper-heuristic ensemble method for static job-shop scheduling. *Evolutionary Computation* 24(4), 609–635 (2016)
- [6] Hernández-Arauzo, A., Puente, J., Varela, R., Sedano, J.: Electric vehicle charging under power and balance constraints as dynamic scheduling. *Computers & Industrial Engineering* 85, 306 – 315 (2015)
- [7] (IEC), T.I.E.C.: Electric Vehicle Conductive Charging System?Part 1: General Requirement; IEC 61851-1. London, UK (2001)
- [8] Ingimundardottir, H., Runarsson, T.P.: Discovering dispatching rules from data using imitation learning: A case study for the job-shop problem. *Journal of Scheduling First Online*: 13 June 2017 (2017)
- [9] Kaplan, S., Rabadi, G.: Exact and heuristic algorithms for the aerial refueling parallel machine scheduling problem with due date-to-deadline window and ready times. *Computers & Industrial Engineering* 62(1), 276–285 (2012)
- [10] Koulamas, C.: The total tardiness problem: Review and extensions. *Operations Research* 42, 1025–1041 (1994)
- [11] Koza, J.R.: *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press (1992)
- [12] Mencía, C., Sierra, M.R., Mencía, R., Varela, R.: Genetic algorithm for scheduling charging times of electric vehicles subject to time dependent power availability. In: Ferrández Vicente, J.M., Álvarez-Sánchez, J.R., de la Paz López, F., Toledo Moreo, J., Adeli, H. (eds.) *Natural and Artificial Computation for Biomedicine and Neuroscience*. pp. 160–169. Springer International Publishing, Cham (2017)
- [13] Nguyen, S., Zhang, M., Johnston, M.: A sequential genetic programming method to learn forward construction heuristics for order acceptance and scheduling. In: *Proceedings of the 2014 IEEE Congress on Evolutionary Computation, CEC 2014* (2014)
- [14] Sang-Oh Shim, S.O., Kim, Y.D.: Scheduling on parallel identical machines to minimize total tardiness. *European Journal of Operational Research* 177(1), 135–146 (2007)
- [15] Sedano, J., Portal, M., Hernández-Arauzo, A., Villar, J.R., Puente, J., Varela, R.: Intelligent system for electric vehicle charging: Design and operation. *DYNA* 88(6), 640–647 (2013)



# On the Landscape of a Problem of Finding Satisfactory Metaheuristics

José M. Cecilia, Baldomero Imbernón

*Bioinformatics and HPC Research Group (BIO-HPC)*

*Polytechnic School, Univ. Católica San Antonio of Murcia (UCAM)*

Murcia, Spain

{jmcecilia,bimbernon}@ucam.edu

José-Matías Cutillas-Lozano, Domingo Giménez

*Department of Computing and Systems*

*University of Murcia*

Murcia, Spain

{josematias.cutillas,domingo}@um.es

**Abstract**—Fitness landscape analysis is used to determine the distribution and shape of the fitness function for the space of solutions of optimization problems. It is a hard task which can help in the design of efficient metaheuristics to approach the solution of the problem in hand. This paper studies the landscape of a problem of finding satisfactory metaheuristics. A molecule-docking problem and a problem of determination of kinetic constants in a chemical reaction are used as case studies. We are not working at the level of the case study problems, but at a higher abstraction level, which makes the landscape analysis an even harder task. The metaheuristics being analyzed are developed with a parameterized schema, with each combination of parameters in the schema being an element of the solutions space and a metaheuristic to be applied to the base problem. The fitness for a metaheuristic is measured by applying it to some training instance of that problem. Some highlights are given on how fitness landscape analysis can be conducted for this type of problems. The ideas analyzed with the two case studies can be extended for the development of hyperheuristics searching for satisfactory metaheuristics for other optimization problems.

**Index Terms**—fitness landscape analysis, metaheuristics, hyperheuristics, molecule-docking, reaction kinetics

## I. INTRODUCTION

Metaheuristics are used to approach the solution of complex optimization problems, but the selection of a satisfactory metaheuristic for a particular problem is a difficult task. Fitness landscape analysis has been applied to the field of metaheuristics since the 1980s [1]–[3]. It studies the shape of the fitness in the space of solutions, and gives guidelines for the design of metaheuristics for the problem in hand.

Here we are interested in the landscape of an optimization problem built on top of another optimization problem. Two optimization problems are used at the bottom as case studies: a molecule-docking problem [4] and determining the kinetic constants of a chemical reaction [5]. Several metaheuristics can be applied, and a hyperheuristic (a metaheuristic in itself) searching in the space of metaheuristics is the optimization problem at the top of our hierarchy.

A parameterized schema of metaheuristics is used. It was initially used for the application of several metaheuristics to some optimization problems [6]. The next step led us

to the development of hyperheuristics on top of the metaheuristic schema [7]. These hyperheuristics has high computational costs due to the repeated application of numerous metaheuristic configurations to the problem in hand. The base problem may in turn be computationally demanding, and so the combination of the high computational cost of metaheuristics with that of the hyperheuristics working on top of metaheuristics advises the exploitation of parallelism at both levels [8]. But even the efficient exploitation of parallelism is not enough to reduce the search to an acceptable time, and so fitness landscape analysis can guide the search for satisfactory metaheuristics. The conclusions drawn here can be applied to the problem of searching for satisfactory metaheuristics for other optimization problems.

The rest of the paper is organized as follows. Section II briefly describes the two case studies. The general ideas of the parameterized metaheuristic schema and the hyperheuristic developed on top of it are presented in Section III. The fitness landscape analysis is shown in Section IV. Finally, Section V summarizes the conclusions and gives some directions for future work.

## II. CASE STUDY PROBLEMS

### A. The Molecule-Docking Problem (MDP)

Virtual Screening (VS) methods analyze large libraries of small molecules (*ligands*) to search for those structures which are most likely to bind to a protein receptor or enzyme [9]. VS is computationally demanding and requires the application of approximate optimization and high performance computing techniques [10], [11].

Molecular docking is used to predict non-covalent binding of molecules. Normally, the molecules to be bound are a macromolecule (receptor) and a small molecule (ligand). There are several scoring functions that can be used to measure the strength of the bond [12]. The Lennard-Jones potential is used here. The sum of the interactions of each atom of an active site of the protein with each atom of the ligand is computed. So, the computing cost is quadratic in the sizes of the molecules.

The ligand can bind at several spots on the receptor molecule. There are six degrees of freedom for the ligand, three for its translation and three for the rotation. The spot, translation and rotation which give the lowest value of the

Supported by the Spanish MINECO and European Commission FEDER funds, under grants TIN2015-66972-C5-3-R and TIN2016-78799-P (AEI/FEDER, UE).

scoring function are sought. The values of the movements and rotations of the ligand can be approached with metaheuristics, and a search is conducted in the neighborhood of each spot. So, independent metaheuristics are applied at each spot and the reference set for the search is composed of a subset for each spot.

### B. Kinetic Constants of a Chemical Reaction (KCP)

When chemical reactions occur in heterogeneous phase the variables that affect the reaction rate are temperature, pressure, composition and mass transfer rate. The kinetics of the dissolution of calcium carbonate is used for the experiments. It is a function of the concentration of the various carbonate species in the solution and, therefore, a function of the partial pressure of carbon dioxide and pH. Depending on the value of the pH, there are different ways in which the dissolution occurs: by reaction with acetic acid, by reaction with carbonic acid, and by the hydrolysis reaction [13]. Therefore, the variation of moles of calcium over time is

$$\frac{1}{V} \frac{dN_{Ca^{2+}}}{dt} = -k_1 a^{n_1} [H_3O^+]^{n_2} - k_2 a^{n_3} [H_2CO_3]^{n_4} - k_3 \quad (1)$$

where  $k_i$  are the combined reaction rate constants,  $n_i$  are the reaction orders, and  $a$  is the area of the tablet, which is known for each increase of time. The integration of the equation for a certain value of time,  $t_j$ , gives the increase of calcium in the solution as a function of the concentrations of protons and carbonic acid. An individual is represented by a real vector of size seven. Every time the fitness of an individual is computed, the whole chemical system is solved with an iterative process, and the fitness is obtained by comparing the values obtained with the simulation with those obtained experimentally.

## III. PARAMETERIZED METAHEURISTICS AND HYPERHEURISTICS

The application of a parameterized schema of metaheuristics (Algorithm 1) to the two case studies is considered. Schemas of this type have been applied to other problems, and the fitness landscape analysis techniques here used can be extended to other hard optimization problems.

### Algorithm 1 Parameterized metaheuristic schema

```
Initialize(S, ParamIni) //Generate initial set and improve elements
while (not EndCondition(S, ParamEnd)) do
  SS=Select(S, ParamSel) //Select elements for combination
  SS1=Combine(SS, ParamCom) //Combine pairs of elements
  SS2=Improve(S, SS1, ParamImp) //Improve and diversify
  S=Include(S, SS1, SS2, ParamInc) //Update the reference set
end while
```

The schema comprises some basic functions which work on sets ( $S$ ,  $SS$ ,  $SS1$  and  $SS2$ ) of configurations. Some metaheuristic parameters ( $ParamX$ ) are included in each basic function, which can be implemented in different ways, and the number of parameters and their meanings also change. Landscape analysis is conducted to study the influence of the parameters on the fitness. The sets, the basic functions and

the meaning of the metaheuristic parameters in the schema are commented on.

**Initialize:** Sets of candidate solutions are randomly generated. For the MDP, a subset is generated at each spot, but in the experiments only one spot is considered for low execution times. The number of elements is given by the parameter Initial Number of Elements ( $INEIni$ ), which determines if the metaheuristic is closer to a local search ( $INEIni = 1$ ) or to a population based method.

Some of the generated elements are improved, and the intensity of the improvement can be varied to determine the importance of the local search in the metaheuristic. A percentage ( $PEIIni$ ) of the elements is improved by comparing its fitness with that of a neighbor configuration, which substitutes the original element if the fitness is improved. The intensity of the improvement is determined by parameter  $IIEIni$ , which represents the maximum number of neighborhood analysis steps.

Another intensification parameter is considered for MDP. A ligand has a number of flexibility junctions determined by its crystallographic structure. In the intensification,  $NEIFlex$  represents the number of configurations obtained by rotation of the junctions to be evaluated for each candidate element. This parameter depends on the characteristics of the ligand, and so the same value is considered for improvements in the functions of the schema (after initialization and in the improvements inside the loop).

A number of the best elements is selected for the following iteration. The implementations for the two problems differ slightly at this point. In the KCP only one parameter is used, for the Number of Best Elements to include ( $NBEIni$ ). But in the MDP a Number of Best Elements ( $NBEIni$ ) and of Worst Elements ( $NWEIni$ ) is established, in order to not concentrate the search on only the most promising areas. The selection can be made in different ways (random, roulette, etc). Our implementation selects the  $NBEIni$  best elements, and  $NWEIni$  elements are randomly selected from the half elements with the worst scores.

**EndCondition:** Typically, the end condition of a metaheuristic is a maximum number of iterations ( $MNIEnd$ ) or a maximum number of iterations without improving the best solution ( $MIREnd$ ). Because we are interested in the study of the influence of the parameters on the fitness, the experiments are carried out for fixed times.

**Select:** A number of the best ( $NBESel$ ) and the worst ( $NWESel$ ) elements of the reference set are selected. The selection is made in the same way as the elements to be included in the reference set are selected for the MDP after the improvement in the initialization.

**Combine:** A number of combinations is carried out between best ( $NBBCom$ ), worst ( $NWWCom$ ) and best-worst ( $NBWCom$ ) pairs of elements. The inclusion of worst elements diversifies the search. In the MDP the combination of a pair of elements gives a new element obtained as the mean of the translation and rotation parameters of the two elements. In the KCP, the classical crossing by a middle point is used.



**Improve:** Some of the elements obtained by combination are improved in the same way as in the improvement in the initialization. The percentage of elements to be improved is  $PEImp$ , and the intensification of the improvement is determined by  $IEImp$ .

A diversification strategy is applied to avoid falling into local minima. The percentage of elements from the reference subsets to be diversified is  $PEDImp$ , and the elements obtained by diversification are improved with an intensification  $IIDImp$ . An element is diversified by randomly generating a new value for one of its parameters, which is selected randomly. The elements generated by diversification are improved to avoid early death.

**Include:** The  $NBEInc$  best elements from all those in the reference set and those generated by combination, diversification and improvement are included in the reference set for the next iteration. The reference set is completed with  $FNEIni - NBEInc$  elements randomly selected from the remaining ones.

There are eighteen metaheuristic parameters in the implementation for the MDP and sixteen for the KCP, and their influence on the fitness was analyzed varying the execution time and without considering the end condition parameters.

Hyperheuristics are methods for the selection of satisfactory metaheuristics [14]. The schema in Algorithm 1 can be used for the development of hyperheuristics. The optimization problem now consists in selecting the values of the metaheuristic parameters which give the best fitness for some training problems. The hyperheuristic is therefore another metaheuristic that can in turn be developed as a parameterized metaheuristic with the parameterized schema. The general ideas of this type of hyperheuristics when applied for the two case studies are:

- The possible solutions for the hyperheuristic are vectors of metaheuristic parameters (metaheuristics). The sizes of the vectors depend on the implementation of the parameterized schema: 18 or 16 parameters for the MDP and the KCP, with only 16 or 14 if the end condition is a fixed execution time. The hyperheuristic searches in a predetermined search range for each parameter. For the experiments with the MDP,  $INEIni$  varies between 20 and 200, and a range between 0 and 100 is established for the rest of the parameters; and with the KCP,  $INEIni$  and  $FNEIni$  are between 20 and 200, the intensification parameters between 0 and 50 and the rest of the parameters between 0 and 100.
- The fitness for each metaheuristic is obtained through its application to some training problems. Only one training problem can give problem-dependent results, and a large number of training problems means large execution times. Fitness landscape analysis can help in determining how a particular problem is representative of the behavior of other problems.
- The execution time of a hyperheuristic of this type is very high due to the repeated application of metaheuristics to the training instances. So, the analysis of the fitness land-

scape could help to guide the search of the hyperheuristic for low search times.

- In general, to reduce the high execution times, the metaheuristic parameters for the hyperheuristic will be smaller than those of the metaheuristics it searches for. The sets in the search are smaller, as are the number of elements to be improved and the intensification of the improvement.
- The improvements in the initialization and inside each iteration are carried out by analyzing elements in the neighborhood, with the neighbors of an element being those which are obtained from it by changing one element of the metaheuristic parameter vector (increasing or decreasing by one).
- The combination of a pair of metaheuristics is carried out with the typical method of selecting a crossing point and combining the initial part from one ascendant with the second part from the other. If an invalid configuration of the metaheuristic parameters is generated, it is discarded.
- The diversification consists of the substitution of the value of a randomly selected metaheuristic parameter by another value randomly selected from the search range for this parameter.

There is an optimization problem at the bottom (MDP or KCP), and the fitness landscape analysis of metaheuristics for this problem studies the shape of the fitness function for some instances of the problem. At a higher abstraction level, the hyperheuristic is now the metaheuristic to be guided with the results of the fitness landscape analysis.

#### IV. FITNESS LANDSCAPE ANALYSIS

The fitness landscape analysis of the problem of finding satisfactory metaheuristics for an optimization problem is a hard task. The fitness of each metaheuristic is measured through its application to various training instances of the problem. The optimization problem can have high computational costs, which, together with the number of training problems, means high execution times. Furthermore, the results obtained with one or several training problems should be representative for other problems. For simplification, for the two case studies experiments were carried out for three instances of the problem and for 100 randomly generated metaheuristics, with the values of the metaheuristic parameters in the ranges previously indicated.

The characteristics of the pairs for the MDP are given in Table I; they correspond to the Angiotensin-converting enzyme (ACE), the Glycogen phosphorylase beta (GPB) and the Poly(ADP-ribose) polymerase (PARP), and the table shows the number of atoms of the receptor and the ligand and the number of junctions of the ligand. The best fitness when applying each metaheuristic to the corresponding receptor-ligand pair was stored at intervals of 30 seconds, starting at 30 seconds and finishing at 600 seconds. Three experiments for which laboratory data are available are used for the KCP. In this case, each metaheuristic is run for 100 seconds, and the fitnesses obtained at intervals of 5 seconds are stored. The results of the experiments are analyzed to study three aspects:

TABLE I  
CHARACTERISTICS OF THE RECEPTOR-LIGAND PAIRS USED IN THE  
EXPERIMENTS.

pair	#atoms receptor	#atoms ligand	#junctions
ACE	9198	59	13
GPB	13261	29	1
PARP	5588	32	3

- The influence of the parameters in the fitness is analyzed, both individually (which parameters influence the fitness most and if the influence is positive or negative) and globally (if the distance between metaheuristics is related to the difference of their fitnesses). The hyperheuristics could concentrate the search in the parameters which prove to be the most influential, and in the ranges where the best fitnesses are obtained.
- The influence of the execution time on the distribution of the fitness and on the influence of the parameters in the fitness. This study can help establish a time limit for the application of the metaheuristics to the training problem, so reducing training time.
- Whether the results obtained for one instance are similar to the others. If they are similar or if some relation between them can be deduced, the number of training problems could be low (in the best case only one), so reducing training time.

The influence of the metaheuristic parameters on the fitness can be analyzed to determine the parameters with most influence and the ranges where the search should be concentrated. The evolution of the correlation coefficient of the metaheuristic parameters with respect to the fitness is shown in Figures 1 (MDP) and 2 (KCP). A negative value indicates that when the value of the parameter increases the fitness improves (decreases). The figures on the left show the coefficient for the parameters with the greatest positive influence on the fitness, and those on the right correspond to the other parameters. The colors identify the basic functions in the schema: blue for initialization, red for selection, black for combination, brown for improvement, cyan for inclusion, and green for *NEIFlex*.

In the MDP, the parameter which most positively influences the fitness is not always the same. For ACE it is *NEIFlex*, which also influences PARP, but with no influence on GPB. It can be logical if we consider the number of flexible junctions in each case, which is 13 for ACE, 3 for PARP and 1 for GPB (Table I). So, it seems the search by flexing the ligand is more advisable for more flexible junctions. Another influential parameter is *NBEInc*, with a correlation coefficient of around -0.2 in ACE and PARP, and a little higher than -0.1 in GPB. It is also normal that considering a large number of promising elements will provide better fitness. The percentage of elements to diversify (*PEDImp*) is the best parameter for GPB and PARP, and the value is slightly higher than -0.2 in ACE. So, it seems that diversification is better than exploring the neighborhood of promising metaheuristics. Surprisingly, the combination of non promising elements (*NWWCom*)

seems to be the fourth parameter in importance for good fitness, maybe because combining these elements avoids intensification in their neighborhood.

The relevance of the parameters changes for the KCP. The most relevant parameter is always clearly *IDEImp*, which has an inverse relation with the fitness, so it is advisable not to work too much on the improvement of elements after diversification. The other parameters have little influence. The initialization parameters have in general a positive influence and, in particular, the improvement parameters in the initialization. The improvement of the elements in the successive steps (*PEIImp* and *IIEImp*) also has a positive influence. So, the local searches lead to better results for this problem.

In any case, independently of which parameters have most influence on the fitness, the analysis can serve to guide the hyperheuristic according to the problem it is being applied to and the particular implementation of the parameterized metaheuristic schema for that problem.

There is a need to reduce the training time of hyperheuristics. Figures 1 and 2 show the relation of the metaheuristic parameters with the fitness at several time-steps. After a time (around 250 and 50 seconds) the influence is stable. Furthermore, as can be seen in Figure 3, the correlation coefficient of the fitnesses obtained at one time step with respect to those obtained at the final time is higher than 0.9 after 250 seconds for the MDP and after 60 seconds for the KCP. With the application of the metaheuristics to a training problem we are not searching for optimum solutions for this particular problem, but for satisfactory metaheuristics for the general problem. So, the training time could be reduced to approximately half the time used in the experiments.

There are other possibilities to reduce the training time. For example, with the 100 metaheuristics experimented with in 20 time-steps, if the five metaheuristics with the worst fitness are discarded at each step, the total training time is halved. The difference in the behavior with the different problems and instances considered can be seen in Figure 4, where the mean fitness of the five metaheuristics discarded at each time step is shown. The similarity in the results for GPB is observed in its flat shape. For the MDP, the slope of the lines seems to be related to the number of flexible junctions (Table I) and the difficulty of approaching the optimum.

## V. CONCLUSIONS AND FUTURE WORK

This paper presents a first approach to the analysis of the fitness landscape for the problem of finding satisfactory metaheuristics for hard optimization problems. A molecule-docking problem and a problem of obtaining the values of kinetic constants are used as case studies, but the same methodology can be applied to the search for metaheuristics for other problems. The metaheuristics considered are implemented with a parameterized schema, which is used for the development of a hyperheuristic which searches in the space of metaheuristics. The fitness for each metaheuristic is obtained with its application to some training problems. The main difficulty in the fitness landscape analysis is the

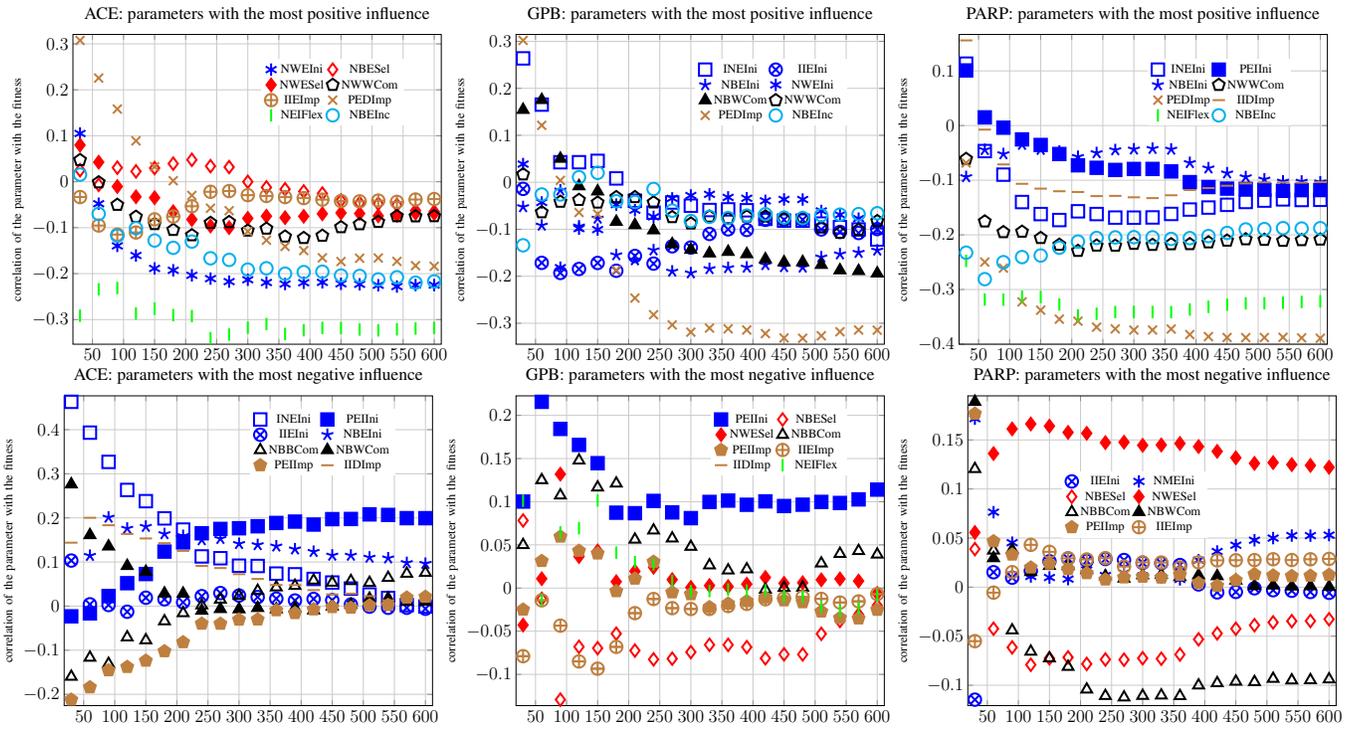


Fig. 1. Evolution of the correlation coefficient of the metaheuristic parameters with the fitness, for the MDP, for several execution times for the receptor-ligands ACE (left), GPB (middle) and PARP (right). Top: the eight parameters with the most direct relation with the fitness after 600 seconds; Bottom: the eight parameters with the most inverse relation.

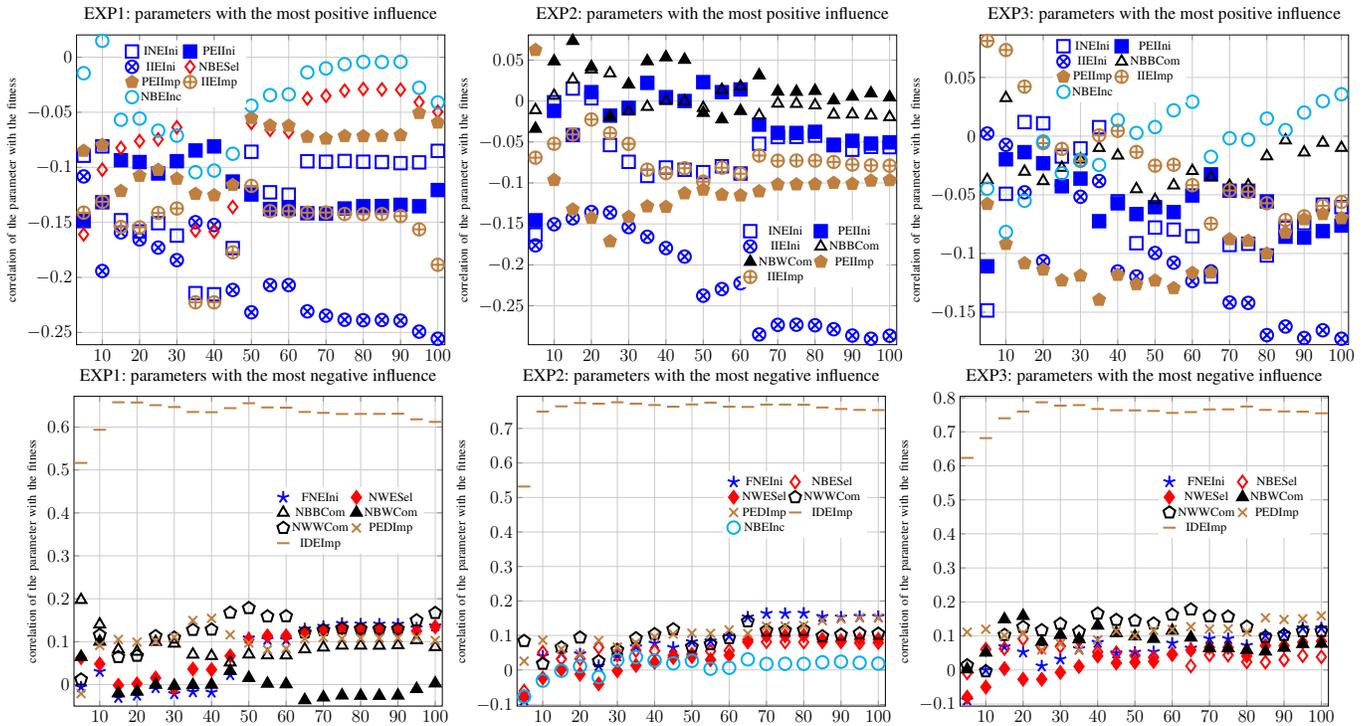


Fig. 2. Evolution of the correlation coefficient of the metaheuristic parameters with the fitness, for the KCP, for several execution times for the experiments EXP1 (left), EXP2 (middle) and EXP3 (right). Top: the seven parameters with the most direct relation with the fitness after 100 seconds; Bottom: the seven parameters with the most inverse relation.

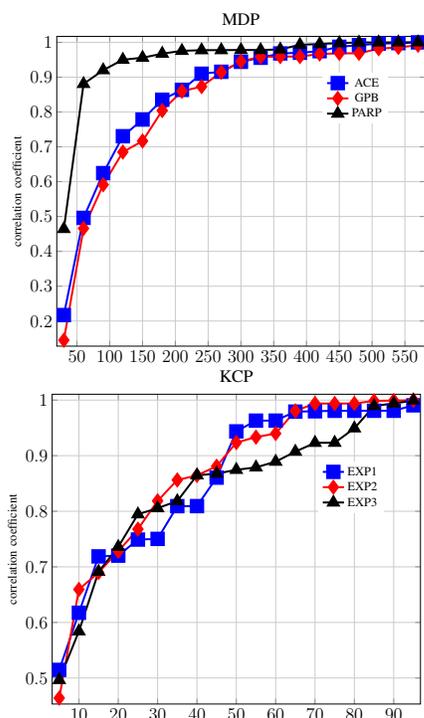


Fig. 3. Evolution of the correlation coefficient of the fitness at different time-steps with respect to the fitness. Top: MDP after 600 seconds; Bottom: KCP after 100 seconds.

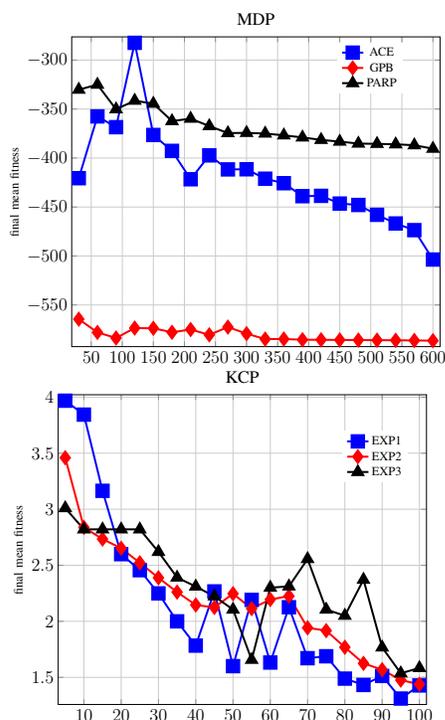


Fig. 4. Mean of the final fitness of the metaheuristics discarded at different times-steps. Top: MDP, plot each 30 seconds; Bottom: KCP, plot each 5 seconds.

randomness of the application of the metaheuristics, which makes the surface of the fitness function dependent on the random execution and on the instances used in the training process. The influence of the parameters and of the training time on the fitness has been experimentally analyzed.

The results of our analysis are being used to guide the implementation of hyperheuristics on top of the parameterized metaheuristic. More experiments with more instances of the case study problems are needed, and similar studies for other optimization problems at the bottom of the metaheuristics hierarchy will be conducted.

## REFERENCES

- [1] W. Hordijk, "A measure of landscapes," *Evol. Comput.*, vol. 4, pp. 335–360, Dec. 1996.
- [2] K. Malan and A. P. Engelbrecht, "A survey of techniques for characterising fitness landscapes and some possible ways forward," *Inf. Sci.*, vol. 241, pp. 148–163, 2013.
- [3] P. F. Stadler, "Towards a theory of landscapes," in *Complex Systems and Binary Networks*, vol. 461 of *Lecture Notes in Physics*, ch. 10, pp. 78–163, 2007.
- [4] E. López-Camacho, M. J. García-Godoy, J. García-Nieto, A. J. Nebro, and J. F. A. Montes, "Solving molecular flexible docking problems with metaheuristics: A comparative study," *Appl. Soft Comput.*, vol. 28, pp. 379–393, 2015.
- [5] J. Cutillas-Lozano and D. Giménez, "Determination of the kinetic constants of a chemical reaction in heterogeneous phase using parameterized metaheuristics," in *Proceedings of the International Conference on Computational Science*, pp. 787–796, 2013.
- [6] F. Almeida, D. Giménez, J.-J. López-Espín, and M. Pérez-Pérez, "Parameterised schemes of metaheuristics: basic ideas and applications with Genetic algorithms, Scatter Search and GRASP," *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, vol. 43, no. 3, pp. 570–586, 2013.
- [7] J. Cutillas-Lozano, D. Giménez, and F. Almeida, "Hyperheuristics based on parametrized metaheuristic schemes," in *Proceedings of the Genetic and Evolutionary Computation Conference*, pp. 361–368, 2015.
- [8] J. M. Cecilia, J.-M. Cutillas-Lozano, D. Giménez, and B. Imbernón, "Exploiting multilevel parallelism on a many-core system for the application of hyperheuristics to a molecular docking problem," *The Journal of Supercomputing*, Mar 2017.
- [9] U. Rester, "From virtuality to reality-Virtual screening in lead discovery and lead optimization: a medicinal chemistry perspective," *Current Opinion in Drug Discovery & Development*, vol. 11, no. 4, pp. 559–568, 2008.
- [10] S. Garcia Sanchez, E. Ramirez Aportela, J. I. Garzón, P. Chacón, A. S. Montemayor, and R. Cabido, "FRODRUG: A virtual screening GPU accelerated approach for drug discovery," in *22nd Euromicro International Conference on Parallel, Distributed, and Network-Based Processing*, pp. 594–600, 2014.
- [11] B. Imbernón, J. M. Cecilia, and D. Giménez, "Enhancing metaheuristic-based virtual screening methods on massively parallel and heterogeneous systems," in *Proceedings of the 7th International Workshop on Programming Models and Applications for Multicores and Manycores*, pp. 50–58, 2016.
- [12] E. Yuriev, M. Agostino, and P. A. Ramsland, "Challenges and advances in computational docking: 2009 in review," *Journal of Molecular Recognition*, vol. 24, no. 2, pp. 149–164, 2011.
- [13] L. N. Plummer, T. M. L. Wigley, and D. L. Parkhurst, "The kinetics of calcite dissolution in  $CO_2$ -water systems at 5 to 60°C and 0.0 to 1.0 atm  $CO_2$ ," *American Journal of Science*, vol. 278, pp. 179–216, 1978.
- [14] E. K. Burke, M. Hyde, G. Kendall, G. Ochoa, E. Özcan, and J. Woodward, *A Classification of Hyper-heuristic Approaches*, pp. 449–468. Springer, 2010. In Michel Gendreau, Jean-Yves Potvin, editors, *Handbook of Meta-heuristics*.



# Generador de Planificaciones Conjuntas para Cuadrante de Rotación de los Conductores de Autobuses

Eva M. Almansa Aránega

Dept. Ciencia de la Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
Eva.M.Almansa@gmail.com

Samuel Lopéz Liñán

Dept. Ciencia de la Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
samusanlzl@gmail.com

Francisco José Rodríguez Serrano

R&D Coordinator  
SHS Consultores S.L.  
Sevilla, España  
fjrodriguez@shsconsultores.es

José Manuel Benítez Sánchez

Dept. Ciencia de la Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
J.M.Benitez@decsai.ugr.es

**Abstract**—El Problema de Generación de Cuadrante de Rotación de los Conductores de Autobuses (PGCRCA) se refiere a la planificación del horario de trabajo de los conductores a lo largo de un determinado periodo de tiempo, como por ejemplo un año. Es un problema de naturaleza NP-duro donde habitualmente existen un número alto de restricciones a cumplir, dificultando las decisiones en cada paso de la construcción de una solución. Existen distintas propuestas de resolución de versiones simplificadas en la literatura. En este trabajo abordamos un problema real con amplia diversidad de restricciones y un número mucho mayor del recogido en las publicaciones: diferentes planificaciones que comparten recursos. Hemos desarrollado una heurística que resuelve eficazmente todos los casos reales planteados por empresas de distinto tamaño del sector. Eficacia y eficiencia de la heurística han sido evaluadas en un extenso conjunto de casos reales y se ha podido constatar las buenas propiedades computacionales del algoritmo.

**Keywords**—cuadrantes de rotación de conductores de autobuses; rotación acíclica; backtracking

## I. INTRODUCCIÓN

Dentro de la gestión de transporte de viajeros en transporte público (TP), un problema es la asignación del horario de trabajo para cada uno de sus conductores de autobuses. El horario de trabajo presenta un alto coste a la empresa. No sólo para obtener una correcta asignación de tareas se debe de tener en cuenta el convenio colectivo, sino además la equidad en el horario de cada conductor. De este modo, el reparto de tareas repercute directamente en el coste para la empresa y en la satisfacción de cada conductor.

La rotación se encuentra en distintos contextos laborales y es uno de los problemas que menos se ha tratado en la literatura académica en comparación con el problema *Cuadrante de Personal* (PCP). Su complejidad reside en la asignación de

turnos y descansos con condiciones similares dentro de un periodo determinado y su *rotación* en el siguiente periodo, según corresponda, hasta completar el tiempo de planificación.

El tipo de problema a resolver, a su vez presenta una versión distinta a todas las recogidas en la literatura, diferentes planificaciones de forma simultánea. Lo cual requiere de una propuesta de solución específica.

Un *turno* es una secuencia de tareas a lo largo de un día, el cual tiene características que lo distinguen del resto, como la franja horaria y la hora de inicio y fin. La *homogeneidad* (franja horaria) y la *continuidad* (hora de inicio y fin) se utilizan para valorar la similitud entre los turnos dentro de un periodo. Un *periodo* es el tiempo que determina el siguiente cambio de turno o descanso, puede ser una semana o más de una, a lo largo de una planificación. Una *planificación* se encuentra en un rango desde un fecha determinada y puede comprender hasta un año. Pueden existir varias planificaciones, lo que conlleva un reparto de los recursos, el cuadrante de los conductores. Cada planificación es independiente de las demás con respecto a las características que la definen, como por ejemplo, la fecha de inicialización y finalización; el tipo de turnos; o el tipo de conductores que usa. Los *tipos de conductores* difieren entre sí en la disponibilidad y/o en sus condiciones laborales. Lo cual describe una variante *acíclica* del problema de Generación de Cuadrante de Rotación de los Conductores de Autobuses (PGCRCA), resultando más compleja que la variante *cíclica*, donde no existen diferencias entre las condiciones de los conductores.

Por lo tanto, PGCRCA es considerado un problema de optimización *multi-objetivo* sobre las condiciones para la satisfacción del conductor y el coste de la empresa.

El resto del artículo está organizado de la siguiente forma. En la Sección II, se presenta la revisión bibliográfica sobre la

metodología del PGCRC. Sección III introduce el problema PGCRC. Sección IV presenta la propuesta, el planificador de rotación. Sección V proporciona distintos ejemplos con diferentes características para ilustrar la aplicación del método propuesto. Finalmente, las conclusiones se encuentran en la Sección VI.

## II. ESTADO DEL ARTE

El problema de tener un alto número de restricciones implica un aumento del número de decisiones en la generación de una planificación. Por lo que para comprobar todas las posibilidades sería necesaria una búsqueda recursiva, con el añadido problema del tiempo de complejidad. En [1] define la complejidad del clásico *Problema de Satisfacción de Restricciones* (PSC) utilizando una búsqueda recursiva.

En el PGCRC, para conseguir un reparto equitativo en la carga de trabajo total hay que tener en cuenta demasiados factores. La normativa de los conductores implica no sólo las reglas de su contrato laboral, sino que también hay que considerar la rotación de los turnos y descansos. Por esta razón, podemos encontrar distintas formulaciones con diferentes modelos matemáticos y con diferentes objetivos. Una de las primeras definiciones que se pueden encontrar en la literatura, se encuentra en [2] que define el problema como un *Multi-level Bottleneck Assignment* (MBA) y demuestra que es NP-duro. Como propuesta, describe un algoritmo que resuelve de forma iterativa un conjunto de sub-problemas para obtener una solución “óptima asintóticamente”. De este modo, se puede encontrar en la literatura distintos enfoques para tratar de resolver este tipo de problema. Algunas propuestas, tales como en [3] con dos heurísticas evolutivas; y en [4] con una solución basada en la técnica *colonia de hormigas* comparada con dos técnicas, *búsqueda tabú* y *enfriamiento simulado*. Otros enfoques como, [5] divide el problema en dos etapas: primero resuelve el problema de modo *cíclico*, es decir, todos los conductores son de igual tipo, con iguales condiciones; y segundo aplica una mejora con un *algoritmo genético*.

El [6] contiene las definiciones, anotaciones, y propone una taxonomía del problema de Cuadrante de Rotación (PCR). De este modo, se puede conocer el alcance y diferencias entre todas las variantes posibles dentro del contexto del PCR. Al igual que se logra comprender la dificultad de la generación de una solución factible según qué variante estemos tratando.

Los [7] y [8] recogen revisiones bibliográficas de distintas especificaciones del PCR. Por un lado, el [7] propone resolver de forma conjunta el PCP y el PCR, basándose en otros artículos que integran los dos problemas en uno; y la regulación a la hora de asignar turnos para una mayor satisfacción de los conductores. El modelo consiste en resolver los dos problemas de forma relajada inicialmente y luego en aplicar unas *post-optimizaciones* para obtener soluciones alternativas que mejoren los resultados hasta llegar al óptimo o hasta los criterios de parada que se establezcan. La función objetivo que establecen para buscar la equidad entre los conductores, es la suma del valor absoluto de la distancia de cada turno (media de horas mensuales trabajadas) a un objetivo de número de horas mensuales. Por otro lado, el [8] en su propuesta trata conjuntamente las dos variantes del PCR:

rotación *cíclica* y *acíclica*. *Cíclica* se refiere cuando los conductores pertenecen a la misma clase y la rotación es exactamente igual en la línea de trabajo, variando únicamente la hora de inicio. *Acíclica* se refiere a que cada conductor tiene distintas condiciones por lo que existen distintos tipos de conductores.

## III. CUADRANTE ROTACIÓN DE CONDUCTORES DE AUTOBUSES

La generación de cuadrantes de rotación es considerada un problema que forma parte de un área clásica (Sistema de planificación de transportes) en el campo de la investigación de operaciones en el ámbito de los sistemas de transportes. Tradicionalmente este problema se ha subdividido en varios sub-problemas debido a la complejidad del mismo. En la Fig. 1, aparecen descritos éstos y el flujo clásico de resolución de los mismos [9]). A continuación, describiremos de forma general cada uno de los problemas:

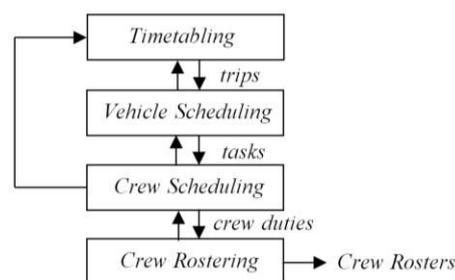


Fig. 1. Sub-problemas del sistema de planificación de transportes.

1) *Generación de horarios (Timetabling)*[10]: Partiendo de la información sobre el número de líneas y el número de servicios y/o frecuencias requeridas se generan los horarios de cada una de las líneas. Estos horarios incluyen los trayectos, cada uno de los cuales se describe con hora de salida, hora de llegada, punto de partida y punto de llegada.

2) *Planificación de vehículos (Vehicle scheduling problem)* [11]: Sobre la base de los trayectos generados en la fase anterior, el objetivo en esta etapa es optimizar el uso de los vehículos de forma que se cubran todos los trayectos definidos en la etapa anterior y se minimice el coste de operación. Este coste de operación viene definido por factores como el número de autobuses necesarios, los kilómetros recorridos, y los tiempos de espera de los vehículos entre distintos trayectos.

3) *Planificación de conductores (Crew/bus-driver scheduling Problem)* [12]: Una vez se dispone de una asignación de vehículos a los distintos trayectos es necesario asignar conductores que cubran de forma óptima las tareas diarias, esto es, la conducción desde el depósito de vehículos al comienzo de la jornada hasta la vuelta al mismo al final de la jornada. Cada una de estas tareas se puede dividir en sub-tareas que vienen definidas por estaciones o puntos en los que es posible realizar un cambio de conductor. Por tanto, el resultado final es la generación de un conjunto de sub-tareas y su asignación a un conductor. Usualmente esta planificación tiene un horizonte temporal corto, aproximadamente 24 horas.

4) *Generación de cuadrantes de rotación (Bus crew rostering problem)* [12]. En este caso se genera una planificación de los turnos de trabajo con un horizonte



temporal más amplio que para el caso anterior, por ejemplo 1 mes o 1 año, aparte de tener en cuenta ciertas restricciones como puede ser el número de horas de descanso entre dos turnos de trabajo, número de días libres, etc. El resultado final es una secuencia de asignación de tareas diarias para cada conductor que tenga en cuenta las restricciones fijadas y que consiga minimizar los costes de operación.

El PGCRCa se puede formular en los siguientes términos: los servicios a prestar están organizados en un conjunto de turnos, repartidos por días según un calendario establecido. El personal está compuesto por un conjunto de conductores, con características posiblemente distintas en cuanto a disponibilidad (ajena), y tipo de turnos que puede hacer. El objetivo es asignar cada turno a un conductor de modo que se optimicen varios criterios y se cumplan una serie de restricciones, como por ejemplo, contemplar dedicaciones en días laborables y festivos, y respetar días de descanso.

Para generar una solución se tiene una función *multi-objetivo*, con prioridad para cada criterio de optimización. Los criterios de optimización permiten generar diferentes soluciones por ser flexibles en cada aplicación. Sin embargo, las restricciones de los conductores se tienen que cumplir para considerar la solución como factible.

**A. Criterios de optimización**

En orden de mayor a menor preferencia:

- 1) Minimizar el número de conductores en el periodo.
- 2) Minimizar el número de conductores en la planificación.
- 3) Maximizar el número de conductores que cumplen las horas en el periodo.
- 4) Maximizar el número de conductores que cumplen las horas en las planificaciones.
- 5) Maximizar el número de descansos continuos.
- 6) Maximizar el número de asignaciones de turnos en la misma franja (mañana, tarde o noche) a lo largo del periodo, homogeneidad.
- 7) Maximizar el número de turnos con igual características en cada periodo, continuidad.
- 8) Maximizar el número de periodos que cumplan la rotación.

**B. Restricciones de los conductores para ser asignables**

Las restricciones que se han de cumplir son:

- Estar disponible (motivos de no estar disponible serían: vacaciones, enfermedad, baja laboral, o bien, ausencia).
- Cumplir los requisitos para ser asignable, compatibilidad con los turnos y tener un estado asignable (según indique la agenda).
- Cumplir los descansos en el periodo.
- Descanso de al menos 12 horas entre que finaliza un turno y comienza el siguiente.
- No sobrepasar las horas de trabajo indicadas en el periodo.
- Rotación de descansos en días laborables.
- Excepciones de línea.

- Mantener continuidad en los tipos de turnos durante la semana.
- Cuadrantes para una o más planificaciones.
- Se deben repartir todos los turnos durante el tiempo que dure cada planificación.

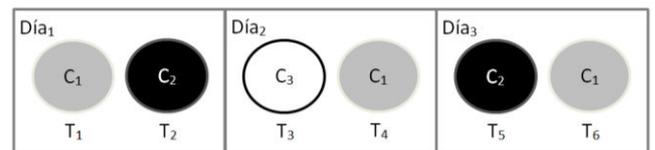
**IV. PLANIFICADOR DE ROTACIÓN**

Denominamos *Planificador de Rotación* (PlanRot) a la propuesta para resolver el problema PGCRCa que hemos desarrollado. PlanRot combina la aplicación de la técnica *backtracking* con distintas etapas de refinamiento (mejora) en la generación de una solución factible.

La Fig. 2 representa un ejemplo de una solución donde cada color del círculo indica una franja horaria distinta. Partimos de una lista de turnos distribuidos a lo largo de los días de la planificación. Para cada turno |T| se realiza una búsqueda de selección del conductor |C| que presente mejores condiciones.

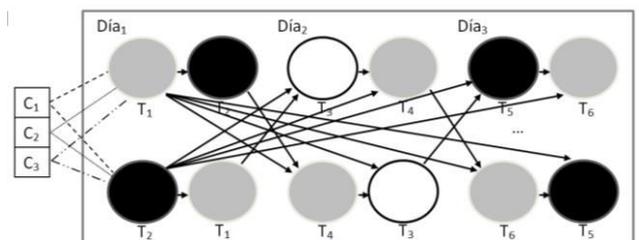
La Fig. 3 es un ejemplo de la estructura del espacio de búsqueda. Ilustra todas las posibles combinaciones que dependen del orden de los turnos y del orden de selección de los conductores. Toda decisión tomada en la asignación de un conductor a un turno repercute en la siguiente asignación. De este modo, el espacio de búsqueda se ve reducido debido a las características de cada turno cubierto, dado que restringe en las siguientes decisiones, al igual que se obtienen valoraciones diferentes en los criterios de optimización.

Fig. 2. Ejemplo de representación de la solución. Aquellos conductores (C<sub>1</sub>, C<sub>2</sub> y C<sub>3</sub>) que mejor cumplan las condiciones son asignados a cada turno (T<sub>1</sub>, ..., T<sub>6</sub>) de la lista que suceden a lo largo de una planificación (Día<sub>1</sub>, Día<sub>2</sub> y Día<sub>3</sub>).



Conductor	Día <sub>1</sub>	Día <sub>2</sub>	Día <sub>3</sub>
C <sub>1</sub>	T <sub>1</sub>	T <sub>4</sub>	T <sub>5</sub>
C <sub>2</sub>	T <sub>2</sub>	-	T <sub>6</sub>
C <sub>3</sub>	-	T <sub>3</sub>	-

Fig. 3. Ejemplo de estructura del espacio de búsqueda. La selección del orden los conductores y el orden en la asignación de turnos representa el espacio de búsqueda.



### A. Heurística. Criterios de optimización

Empíricamente, se ha llegado a la conclusión de que la ordenación de los turnos es significativa. Por lo que, se comienza asignando los turnos por semanas completas, de lunes a domingo (o en su defecto desde el día de inicio de la planificación hasta el domingo). En cada semana se asignan primero aquellos que se encuentren en los días con mayor número de turnos y en caso de que sea igual, se comienza por los turnos del fin de semana.

Para la selección de un conductor se tienen en cuenta la valoración a partir de los criterios de optimización descritos en la Sección III. El orden de prioridad en los criterios de optimización del 1) a 5) es fijo. Los criterios 1) y 2) son los más importantes, por lo que la función objetivo se define con la función *minimizar el número de conductores*. Es decir, durante la generación de la planificación se evalúan distintas asignaciones de conductores a un turno, y se selecciona aquella que presente el mínimo número de conductores. En el caso de que existan soluciones con igual número de conductores se evalúan los criterios de siguiente orden. Se comprobarán en orden desde el 3) al 5) mientras que no resulte una asignación con mejora en algún criterio evaluado, y que por tanto, ya no será necesario evaluar con los siguientes criterios: por ejemplo, si existe una única asignación que presenta mejora con el criterio 3) ya no se evaluarán los criterios 4) y 5). Por otro lado, se permite cambiar la prioridad de los criterios de optimización 6), 7) y 8). De este modo, se pueden obtener diferentes soluciones y posteriormente seleccionar aquella que mejor se ajuste a los criterios de optimización en orden del 1) al 5).

### B. Backtracking. Sistema de penalización

La técnica algorítmica *backtracking* se ha utilizado para la parte principal del problema. Se trata de una técnica exacta que localiza una solución óptima en un espacio de búsqueda cuando se representa en forma de árbol. El mecanismo de exploración que usa es una búsqueda en profundidad (post-orden). Para acelerar el proceso de búsqueda emplea una función de poda que permite descartar subárboles (soluciones parciales y todas las soluciones derivadas de esta) sin tener que explorar todo el subárbol. Así cuando un subárbol es descartado, la exploración vuelve un nivel hacia arriba en el árbol, buscando la siguiente rama a explorar. La exploración de un nodo dado termina cuando se han explorado todos sus hijos. La exploración del árbol completo termina cuando se ha explorado la raíz. Se garantiza así encontrar la solución óptima. Para que el proceso sea computacionalmente factible la definición de la función de poda es crítica. Es fundamental, encontrar una que puede cuanto más mejor. Sin embargo, considerando que el problema es de naturaleza NP-duro siempre existirán casos que obligarán a una exploración muy amplia del espacio de soluciones, con un coste computacional muy elevado.

Para formular el espacio de búsqueda (árbol de búsqueda), las  $n$ -uplas que forman el espacio de soluciones tienen tantas componentes como turnos a cubrir. Los valores que puede tomar cada componente son los posibles conductores. De esta forma, se incluyen todas las posibles asignaciones entre turnos y conductores disponibles. En cada nivel del árbol se evalúan los posibles conductores candidatos a realizarlo.

Para realizar la poda se utiliza el valor de la mejor solución encontrada que es igual al número de conductores (criterios de optimización 1) y 2)) más una pequeña penalización (criterios de optimización del 3) al 8)). Esta penalización, siempre un número racional entre 0 y 1, evalúa otros objetivos secundarios como el que la solución sea poco homogénea (una solución homogénea es cuando los conductores realizan turnos del mismo tipo, mañana o tarde durante una semana y el tiempo de trabajo de los conductores es lo más parecido posible). Estas penalizaciones están directamente relacionadas con los criterios de optimización:

- *Mayor desviación típica sobre el total de minutos de trabajo.*
- *No homogeneidad.*
- *No continuidad.*
- *Descansos no continuos.*
- *Incumplimiento de rotación.*

### C. Métodos de refinamiento

Los métodos de mejora de las soluciones siguen una heurística específica basada en parte en el algoritmo *backtracking*. El recorrido en el método más complejo se basa en asignar un turno específico que no ha sido posible asignar a ningún conductor. Este método intenta asignar el turno al conductor con menos turnos, de forma que si no es posible asignarlo entonces comprueba si quitándole un turno a ese conductor sería posible asignarlo. Si así fuese, entonces se quita un turno y se asigna el turno actual. Luego se repite el mismo procedimiento con el nuevo turno sin asignar que se ha quitado. Además de éste se aplican otros 3 métodos concretos que tratan de mejorar la solución centrándose en cuestiones más específicas.

El algoritmo PlanRot realiza una búsqueda con distintos orden en los criterios de optimización en los criterios 6), 7) y 8); esto implica que resulten diversas construcciones. En muchos casos, las soluciones presentan periodos de tiempo con una incompleta continuidad, homogeneidad e incluso días sin asignar. Los *días sin asignar* aparecen en las semanas en las que no se ha completado el número máximo de turnos para asignar los días de descanso. Este fenómeno está provocado principalmente por dos motivos: uno, la rotación de los turnos y descansos; y dos, el tiempo mínimo de descanso entre que finaliza un turno y comienza el siguiente, sobre todo al rotar de domingo al lunes.

La mejora de la calidad de las soluciones se realiza mediante las siguientes etapas:

1) *Reasignación de turnos*: Los conductores que presentan mayor número días sin asignar se eliminan de la planificación. De este modo todos sus turnos quedan sin asignar. Teniendo en cuenta que, el número máximo de turnos a asignar deberá de ser igual o menor que el número de días sin asignar del resto de conductores. Mientras sea posible, se realiza el intercambio entre los turnos y los días sin asignar más compatibles.

2) *Reasignación de turnos intensiva*: A partir de la etapa previa, se determina el tipo de incompatibilidad en aquellos turnos que no hayan podido ser reasignados con el fin de



reasignarlos en algún otro conductor. Estas incompatibilidades se clasifican en los siguientes casos y se realiza el intercambio siempre que exista otro conductor con el día libre y compatible al turno a asignar:

- Un conductor tiene todos los días de trabajo asignados.
- Franja horaria.
- Rotación de descansos.

3) *Reasignación de descansos*: Recorre cada semana e identifica los conductores con descansos discontinuos. Una vez localizados, realiza un nuevo recorrido para intercambiar entre los conductores identificados los días de descanso. Para realizar el intercambio, al menos tiene que beneficiar a un conductor por conseguir los días de descanso continuos.

4) *Reasignación de turnos no homogéneos*: Recorre cada día y obtiene los turnos no homogéneos de cada conductor y realiza intercambio entre otro conductor con turno no homogéneo. Se selecciona la mejor combinación de intercambio entre turnos no homogéneos.

## V. RESULTADOS EXPERIMENTALES

Se ha aplicado PlanRot sobre casos reales planteados por empresas. Estos casos difieren entre sí en el tamaño, como por ejemplo, número de turnos; número de semanas; tipos de conductores; o número de planificaciones.

La TABLA I. muestra la descripción de cada caso: característica más descriptiva del caso real; el número de planificaciones a resolver; el número de semanas del cuadrante; el número de rotaciones de turnos por periodo; y las rotaciones por semanas en los descansos en días laborables. Los casos de prueba se encuentran ordenados de menor a mayor complejidad.

La TABLA II. contiene los resultados de las soluciones obtenidas comparadas con las soluciones óptimas de cada caso; y el computo de procesamiento en segundos. El número óptimo de conductores se ha obtenido analizando las posibles combinaciones. Asimismo, el algoritmo PlanRot encuentra en todos los casos una solución óptima con el mínimo número de conductores necesario. En general, los casos de prueba que necesitan menos de 10 segundos para obtener una respuesta, son aquellos los que sólo utilizan el método heurístico con los criterios de optimización. El resto presentan mayor tiempo de cómputo por ser necesario aplicar el sistema de refinamiento, con un máximo de menos de 2 minutos.

TABLA I. INFORMACIÓN DE LOS CASOS REALES

Caso	Descripción	Plan	Semanas	Rotación turnos	Rotación descansos
1	Asignación	1	2	-	-
2	2 tipos de días: laborable y no	1	1	-	-
3	2 tipos de conductores	1	1	-	-
4	Comienzo a mitad de la semana, 15 días	1	3	-	-

Caso	Descripción	Plan	Semanas	Rotación turnos	Rotación descansos
5	Rotación descansos	1	2	-	1
6	Agenda conductores	1	1	-	-
7	1 tipo de día	1	4	2	1
8	2 tipos de días	1	4	2	1
9	Comienzo a mitad de la semana, 15 días	1	3	1	-
10	2 tipos días, 2 tipos conductores	1	4	1	1
11	3 franjas horarias	1	2	1	-
12	2 planificaciones	2	1	-	-
13	Larga duración	1	18	1	2
14	Año completo	1	52	1	2
15	3 tipos de conductor	1	2	1	1
16	3 planificaciones	3	2	1	1
17	4 planificaciones	4	2	1	1
18	30 semanas	1	30	1	2
19	40 semanas	1	30	1	2
20	50 semanas	1	50	1	1
21	Distintos periodos (2, 3 y 4 semanas)	3	30	1	1

TABLA II. SOLUCIONES

Nº	Nº óptimo conductores	PlanRot	Tiempo (seg)
1	10	10	5.914
2	9	9	4.506
3	10	10	9.667
4	10	10	11.874
5	10	10	8.432
6	11	11	7.111
7	10	10	9.469
8	9	9	8.533
9	8	8	9.142
10	8	8	4.285
11	13	13	6.386
12	16	16	5.722
13	10	10	24.787
14	18	18	30.895
15	10	10	5.144

Nº	Nº óptimo conductores	PlanRot	Tiempo (seg)
16	20	20	10.054
17	30	30	7.164
18	10	10	63.492
19	10	10	83.022
21	10	10	101.888

## VI. CONCLUSIONES

En este trabajo hemos abordado el problema PGCRCRCA. Se trata de una variante más compleja de un problema de naturaleza NP-duro. La versión estudiada considera distintos tipos de conductores y varias planificaciones simultáneamente. Para resolverlo de forma eficaz hemos propuesto una heurística basada en *backtracking* que combina distintos métodos de refinamiento. La evaluación experimental permite comprobar la eficacia y eficiencia de la propuesta sobre un nutrido conjunto de casos reales.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por los proyectos del Ministerio de Economía y Competitividad TIN2016-81113-R y de Excelencia de la Junta de Andalucía, P12-TIC-2958.

## BIBLIOGRAFÍA

- [1] Marek, Victor W., y Jeffrey B. Rummel. "The complexity of recursive constraint satisfaction problems." *Annals of Pure and Applied Logic* 161 (2009): 447-457.
- [2] Carraresi, P., y G. Gallo. "A multi-level bottleneck assignment approach to the bus drivers rostering problem." *European Journal of Operational Research* 16 (1984): 163-173.
- [3] Xie, Lin, "Metaheuristics approach for solving multi-objective crew rostering problem in public transit," 2013.
- [4] Moz, Margarida, Ana Respcio, y Margarida Vaz Pato, "Bi-objective evolutionary heuristics for bus driver rostering," *Public Transport (Springer Nature)* 1 (aug 2009): 189-210.
- [5] Ma, Jihui, Tao Liu, y Wenyi Zhang, "A Genetic Algorithm Approach to the Balanced Bus Crew Rostering Problem," *Journal of Traffic and Logistics Engineering Vol 2* (2014).
- [6] Ernst, A. T., H. Jiang, M. Krishnamoorthy, y D. Sier, "Staff scheduling and rostering: A review of applications, methods and models," *European Journal of Operational Research (Elsevier BV)* 153 (feb 2004): 3-27.
- [7] Valdes, Vera, y Victor Andres, "Integrating Crew Scheduling and Rostering Problems," Ph.D. dissertation, alma, 2010.
- [8] Xie, Lin, y Leena Suhl, "Cyclic and non-cyclic crew rostering problems in public bus transit.," *{OR} Spectrum (Springer Nature)* 37 (apr 2014): 99-136.
- [9] Freling, R., "Models and Techniques for Integrating Vehicle and Crew Scheduling". Ph.D. thesis, Tinbergen Institute, Erasmus University Rotterdam (1997).
- [10] Ibarra-Rojas, Omar J., y Yasmin A. Rios-Solis. "Synchronization of bus timetabling." *Transportation Research Part B: Methodological* 46 (2012): 599-614.
- [11] Park, Yang-Byung. "A hybrid genetic algorithm for the vehicle scheduling problem with due times and time deadlines." *International Journal of Production Economics* 73 (2001): 175-188.
- [12] Ma, Ji Hui, Tao Liu, y Wei Guan. "Solving Balanced Bus Crew Rostering Problem with Genetic Algorithm." *Sustainable Cities Development and Environment Protection*. Trans Tech Publications, 2013. 2070-2074.

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 4: SESIÓN ESPECIAL:  
SMART CITIES







# Monitorización y clasificación de estancias en edificios empleando captación de comunicaciones inalámbricas de dispositivos inteligentes.

Antonio Fernández Ares  
*Universidad de Granada*  
 Granada, Spain  
 antares@ugr.es

María Isabel García Arenas  
*Universidad de Granada*  
 Granada, Spain  
 mgarenas@ugr.es

Pedro A. Castillo Valdivieso  
*Universidad de Granada*  
 Granada, Spain  
 pacv@ugr.es

**Resumen**—La monitorización de personas y sus movimientos es un área de interés en las *smart cities* ya que estas enfrentan el problema de la superpoblación. Los actuales sistemas de monitorización de personas, basados en cámaras de vigilancia, son muy intrusivos, atentan a la privacidad y son costosos. En este artículo se propone el empleo de la captación de las comunicaciones inalámbricas emitidas por los dispositivos inteligentes portados por los ciudadanos como fuente de datos para los estudios de la monitorización de personas empleando inteligencia computacional para la extracción de patrones de comportamiento habituales. Para ello, se presenta un caso de uso aplicado a la monitorización del acceso a un edificio público y la obtención de los momentos que garantizan la mayor disponibilidad para emplazar eventos no regulares. Los resultados muestran que la captación de comunicaciones inalámbricas y la aplicación de técnicas de aprendizaje máquina permiten estudiar y extraer conocimiento sobre los movimientos de las personas.

**Index Terms**—Ciudades Inteligentes, Monitorización de personas, Comunicaciones inalámbricas, WiFi, Smartphones

## I. INTRODUCCIÓN

La monitorización de personas ha cobrado una gran importancia en el entorno de las *smart cities* debido a que muchos de los problemas a los que se enfrentan las ciudades están originados por el aumento significativo de la población, debido a la superpoblación de las áreas metropolitanas. Proveer de fuentes de datos a las ciudades del futuro sobre los movimientos de las personas que viven en ellas permite una mejor gestión de los recursos, lo que repercute positivamente en la calidad de los servicios ofertados. Este mismo principio puede aplicarse a los edificios de las *smart cities*, obteniendo información real sobre como interaccionan las personas con dicho edificio y emplear la información recogida para la extracción de información y conocimiento por medio de la inteligencia computacional.

Sin embargo, las tecnologías para el conteo y monitorización de personas actuales se encuentran bastante limitadas. Los sistemas que son capaces de reconocer individualmente a las personas son intrusivos y muy costosos tanto monetaria como computacionalmente, pues se basan principalmente en sistemas basados en reconocimiento de imágenes capturadas por cámaras. Los sistemas más simples y baratos, como placas de presión, tornos o haces láser, no son capaces de reconocer visitas sucesivas de un mismo individuo.

En este artículo se propone el empleo de la captación de las comunicaciones inalámbricas WiFi emitidas por los dispositivos inteligentes, como los smartphones, portados habitualmente por las personas. La información capturada permite identificar al dispositivo de forma única y unívoca, lo que permite reconocer al mismo dispositivo en futuras visitas. Las capturas sucesivas de un dispositivo en un lugar acotado, permite delimitar temporalmente la estancia de dicho dispositivo, y por tanto a su portador.

Empleando esta fuente de información se puede obtener la cuantía de visitantes así como la duración de cada visita. Mediante el empleo de técnicas de inteligencia computacional, se puede extraer conocimiento sobre el comportamiento y naturaleza de las distintas visitas, permitiendo obtener los hábitos o patrones distintivos de cada tipo de visitante.

Para estudiar el potencial de la fuente de datos se emplea el sistema *Mobywit* para monitorizar una de las entradas de la ETSIT<sup>1</sup> de la Universidad de Granada. Con los datos obtenidos mediante la detección de los dispositivos inteligentes, se realizan estudios que permitan cuantificar el número de visitantes recibidos en la escuela y mediante el empleo de algoritmos de agrupación ser capaces de extraer patrones que definan los comportamientos de los distintos visitantes.

Los resultados muestran que las estancias reincidentes a lo largo de varios días se pueden agrupar empleando algoritmos de *machine learning* o aprendizaje máquina para extraer patrones habituales de comportamiento, patrones que sirven para comprender mejor la ocupación y saturación del edificio en los distintos momentos del día.

El resto del artículo se estructura como sigue. En la Sección II se presenta un breve estado del arte sobre la monitorización de personas. En la Sección III se presenta la metodología del sistema así como el escenario empleado. En la Sección IV se recogen los experimentos realizados, incluyendo análisis de las estancias, así como los resultados del agrupamiento de las estancias. La Sección V debate sobre los resultados obtenidos en los experimentos. Finalmente la Sección VI alega

<sup>1</sup>Escuela Técnica Superior de Ingenierías en Informática y Telecomunicaciones

la viabilidad de la captación de comunicaciones inalámbricas WiFi para el estudio de la naturaleza de las estancias de las personas en edificios y su importancia en el escenario de un edificio inteligente dentro de una *smart city*.

## II. ESTADO DEL ARTE

Habitualmente la monitorización de personas ha estado asociada a los entornos de marketing y estudios de mercado [1] sin embargo en los últimos años ha cobrado vital importancia en los entornos de las *smart city* [2].

Las tecnologías para el conteo y monitorización de personas han evolucionado desde los sistemas de detección de vehículos [3], resultando en un problema más complejo. Esto se debe principalmente a que las personas no tienen elementos distintivos únicos fácilmente reconocibles por procesamiento OCR<sup>2</sup> de imágenes, al contrario que los coches con sus matrículas [4] y porque sus desplazamientos no se encuentran acotados por carriles y direcciones prefijados [5] como en los vehículos.

Distintas tecnologías han sido empleadas para la contabilización de personas, como los rayos infrarrojos [6] o las cámaras térmicas [7], [8]. Las imágenes captadas por cámaras de vídeo han sido igualmente empleadas [9], [10], siendo algunos sistemas incluso capaces de reconocer a la persona con tasas de acierto aceptables [11]. Sin embargo, estos sistemas tiene numerosos impedimentos como su alto coste [12] y la vulneración de libertades individuales y privacidad [13].

El empleo de los dispositivos inteligentes para la detección de personas es un área de investigación en auge, debido a que su proliferación en los ciudadanos es significativa. Se estima que en España el 83% de la población posee un smartphone<sup>3</sup>.

La detección de estos dispositivos por medio de sus comunicaciones Bluetooth ha sido empleada con éxito para la monitorización de personas tanto en pequeños edificios [14], grandes [15] o ante eventos culturales multitudinarios [16]. Esto posible debido a que el protocolo Bluetooth dispone de mecanismos nativos para la detección de dispositivos cercanos, al estar diseñado para las comunicaciones *device-to-device*<sup>4</sup>.

Las comunicaciones WiFi, en cambio, carecen de mecanismos nativos para la detección de dispositivos, al estar basadas en comunicaciones por infraestructura. Sin embargo, es posible detectar las dispositivos que emplean WiFi capturando los paquetes que emiten [17]. Este tipo de estudios está menos extendido, pero ha sido empleado como pruebas de concepto en escenarios como el Sonar 2015<sup>5</sup> o la Sagrada Familia<sup>6</sup>.

Desde el ámbito académico, la captación de comunicaciones WiFi para la monitorización de personas ha sido empleada con éxito para medir masas de personas [18], tanto en exteriores [19] como interiores [20].

<sup>2</sup>Optical Character Recognition o Reconocimiento óptico de caracteres

<sup>3</sup>Según el último informe anual sobre la sociedad de la información en España elaborado por telefónica <http://www.fundaciontelefonica.com/artecultura/publicaciones-listado/pagina-item-publicaciones/itempubli/483/>

<sup>4</sup>Comunicaciones entre dispositivos sin necesidad de estaciones base.

<sup>5</sup>Por el BSC en el proyecto "We know what you did last Sonar" <http://www.bsc.es/viz/whatyoudid/now.html>

<sup>6</sup>D-lab <https://d-lab.tech/project-1/>

## III. METODOLOGÍA

Para la captación de las comunicaciones inalámbricas WiFi se emplea el sistema *Mobywit* [19], que permite identificar cada dispositivo de forma unívoca mediante un hash de la dirección MAC de la interfaz de red WiFi. La detección de un dispositivo en las inmediaciones del nodo es denominada *paso*, al cual se le asigna una ventana temporal con las marcas de tiempo de la primera y última detección consecutiva. En la Figura 1 se puede observar un diagrama del nodo *Mobywit* emplazado. Es esperable que un mismo dispositivo pueda pasar a lo largo del día varias veces por las inmediaciones del nodo. Para cada dispositivo y cada día, se calcula en base a los sucesivos pasos, el instante de tiempo de entrada y salida al centro, siendo el primer y último paso detectado por el nodo.

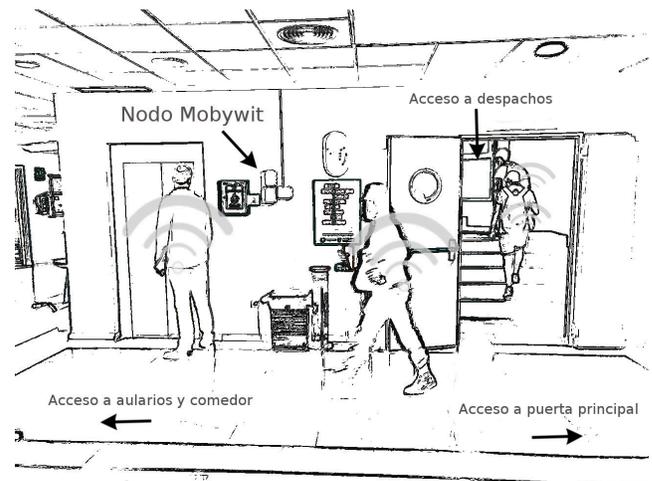


Figura 1. Emplazamiento del Nodo Mobywit en la Escuela. En la parte derecha de la fotografía, fuera de plano, se encuentra la puerta principal. La puerta en plano de la derecha

El escenario de estudio es la Escuela Superior de Ingenierías en Informática y Telecomunicaciones de la Universidad de Granada. Un nodo *Mobywit* fue emplazado en la entrada principal del edificio<sup>7</sup>. Dicha escuela tiene matriculados 2119 alumnos y en ella trabajan unas 250 personas<sup>8</sup>. Las clases tiene una hora de duración, y comienzan a las 8:30.

Durante un periodo de un mes comprendido entre el 3 de Marzo y el 3 de Abril de 2018, incluyendo tanto periodos lectivos como no lectivos, el nodo *Mobywit* capturó 1884219,13MB de tramas WiFi. A partir del procesamiento en tiempo real, el nodo estableció los *pasos* de cada dispositivo por las inmediaciones del nodo.

En base a la información en *pasos* obtenida por el procesamiento de dichas tramas, se propone realizar estudios y aplicar técnicas de aprendizaje máquina para obtener información sobre los hábitos y patrones de comportamiento de los visitantes.

<sup>7</sup>Aunque una puerta secundaria, al ser totalmente exterior, no pudo ser monitorizada al no poder emplazarse el nodo.

<sup>8</sup>Según la memoria académica del curso 2017/2018 [https://secretariageneral.ugr.es/pages/memorias/academica/20162017/docencia/centros/\\_doc/24/!/download](https://secretariageneral.ugr.es/pages/memorias/academica/20162017/docencia/centros/_doc/24/!/download)



IV. EXPERIMENTOS

Los pasos obtenidos se resumen y contabilizan en base a un intervalo de muestreo. La Figura 2 muestra el resultado de este resumen para tamaños de muestreo de un día y una hora. De esta forma, se puede observar como el periodo vacacional de Semana Santa la afluencia de gente se reduce drásticamente, de igual manera que durante los fines de semana.

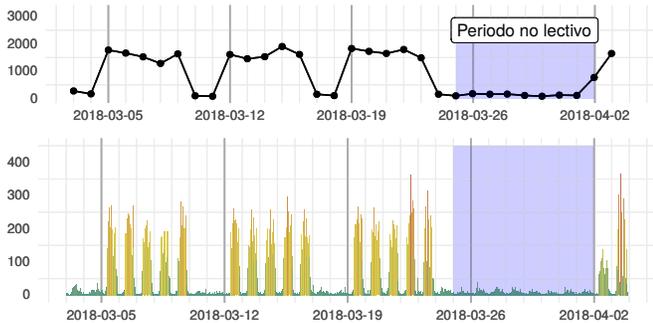


Figura 2. Conjunto de datos obtenidos durante un mes de monitorización. La gráfica superior presenta el número de personas detectadas cada día. La inferior presenta la misma información pero por cada hora.

Esta misma información puede ser mostrada para cada día. La Figura 3 el número de personas detectadas para distintos intervalos de muestreo de un día. Se observa como los cambios de clase afectan al número de personas detectadas.

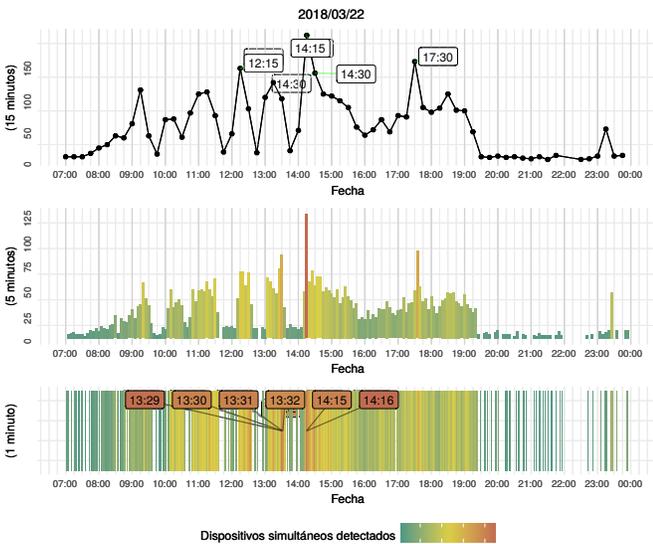


Figura 3. Vista detallada de un día monitorizado, empleando tres tamaños de muestreo: 15 minutos, 5 minutos y 1 minuto. Se han remarcado los valores que han sido considerados anómalos o extremos en las series. Para la ventana de 1 minuto, se emplea únicamente el grado de color como magnitud.

Se espera que cada visitante al edificio registre al menos una entrada y una salida del mismo, siendo registradas ambas en el caso de realizarlas por la puerta monitorizada. Esto permite calcular para cada día el tiempo medio de visitas. La Figura

4 registra la duración de todas las visitas en las que se ha registrado tanto la entrada como la salida.

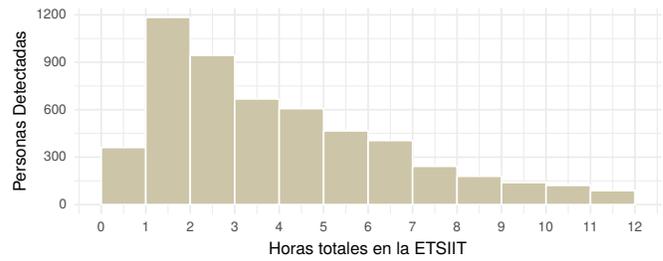


Figura 4. Duración de las visitas registradas. La mayoría de los visitantes están entre una y dos horas en la escuela.

Conociendo tanto la hora de entrada como la hora de salida de cada visitante, se ejecuta el algoritmos de agrupamiento *FarthestFirst* [21]. Para facilitar la interpretación de los resultados del algoritmos de agrupamiento lidiando con fechas y horas, las horas de entrada y salida se resumen en 5 categorías divisorias obtenidas como *boundaires* o fronteras del agrupador. Estas divisiones se recogen en la Tabla I.

Tabla I  
INTERPRETACIÓN DE LOS DIVISORES DE HORAS DEL AGRUPADOR.

Madrugada	$\in (0, 1, 2, 3, 4, 5, 6]$
Mañana	$\in (7, 8, 9, 10, 11]$
Mediodía	$\in (12, 13, 14, 15]$
Tarde	$\in (16, 17, 18, 19, 20]$
Noche	$\in (21, 22, 23]$

El algoritmo de agrupamiento establece cinco clases de visitantes (notadas mediante  $\square$ ,  $\circ$ ,  $\triangle$ ,  $\diamond$  y  $\boxtimes$ ), más una clase auxiliar para las visitas no clasificables o sin un patrón común extraído notado mediante  $+$ . Adicionalmente, en este artículo se notará con el símbolo  $\times$  aquellas visitas registradas mediante un único paso cercano al sensor. En la Tabla II se recogen la asignación de cada divisor de hora a cada clase calculada mediante del algoritmo de agrupamiento.

Tabla II  
CLASES RESULTANTES DEL AGRUPAMIENTO DE CATEGORÍAS

Clase	Entrada	Salida
$\square$ g1	Mañana	Mediodía
$\circ$ g2	Mediodía	Mediodía
$\triangle$ g3	Tarde	Tarde
$\diamond$ g4	Mediodía	Tarde
$\boxtimes$ g5	Mañana	Tarde
$+$	-	*

Para la visita de cada día de cada persona distinta, se dispone de la hora de entrada, la hora de salida y la categoría que le ha asignada mediante el algoritmo de agrupamiento. En la Figura 8 se puede ver como se relacionan las tres variables entre ellas. Las regiones con patrones comunes de entrada y salida han sido asignadas a la misma clase por el algoritmo de agrupamiento. Debido al libre albedrío de las personas, hay visitas que no corresponden a un patrón compartido.

Dichas visitas son notadas mediante **+** y descartadas por el agrupador, en lugar de intentar a ajustarlas de forma artificial a algún patrón o clase ya existente.

detectados varios días distintos o de forma reincidente. Esta regularidad individual, supone a su vez un patrón en si mismo.



Figura 5. Relación entre la hora de entrada, la hora de salida y la clase asignada por el agrupador para todas las visitas de un día determinado.

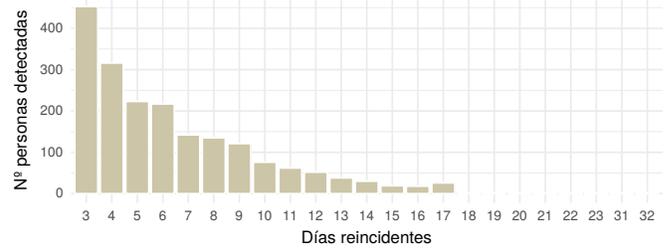


Figura 7. Representación del numero de visitantes reincidentes.

El algoritmo de agrupamiento se aplica a todas las visitas de todos los dispositivos detectados a lo largo de todo el periodo. La figura 6 recoge la relación entre la hora de entrada, la hora de salida y la categoría asignada a la visita para todos los días que han sido monitorizados por el nodo.

Dada la capacidad del sistema *Mobywit* para ser capaz de reconocer de forma reincidente al mismo dispositivo y por tanto a la misma persona, se pueden extraer patrones en los hábitos de una misma persona a lo largo de varios días. La Figura 8 muestra para un subconjunto de personas reincidentes más de 10 veces, la clase asignada a cada una de sus diferentes visitas en diferentes días. En dicha gráfica se puede como las personas se ajustan en su mayoría a un patrón común de comportamiento a lo largo del tiempo.

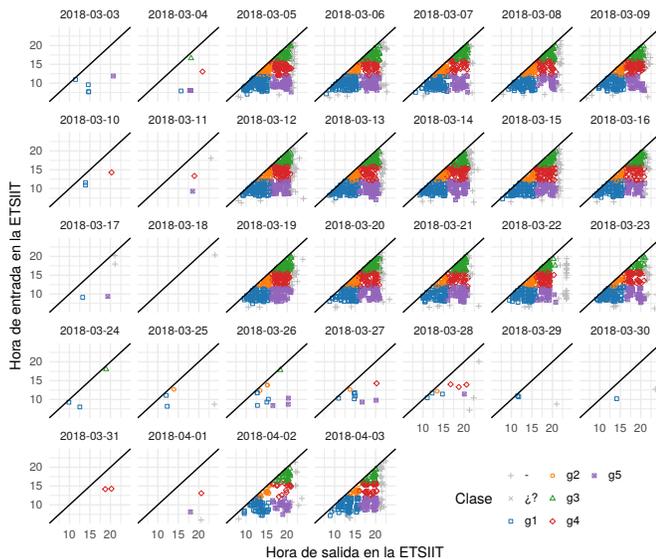


Figura 6. Relación entre la hora de entrada, la hora de salida y la clase asignada por el agrupador para todos las visitas del conjunto de datos.

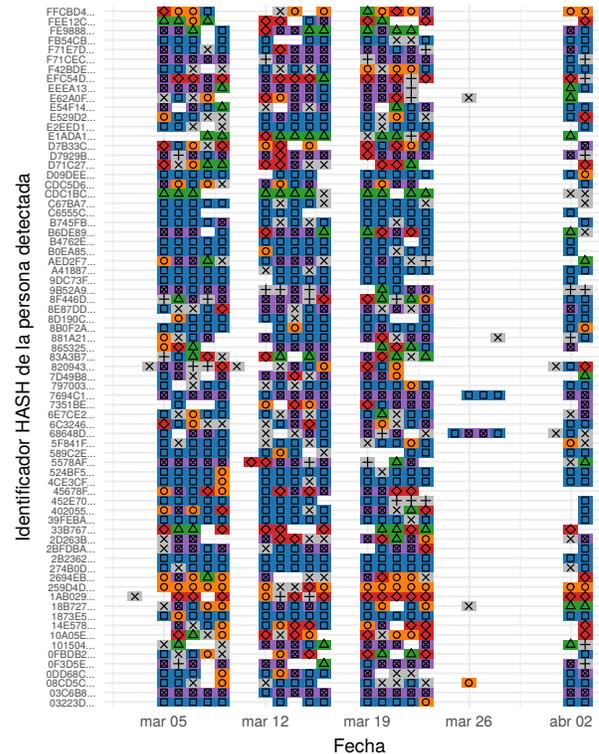


Figura 8. Representación de la clase asignada en diferentes visitas para un subconjunto de visitantes los reincidentes más de diez veces. Se observa como las visitas sucesivas de la mayoría de los visitantes son de la misma clase.



No todas las visitas de una misma persona tiene porque ser clasificadas con la misma categoría, sin embargo si puede ser definida una categoría predominante para cada persona de la cual se extraiga un patrón de comportamiento habitual, aunque debido a circunstancias externas ese patrón no sea perfecto. En la Tabla III se presenta la clase predominante de todos los visitantes ( $n \geq 1$ ) como aquellos reincidentes al menos 10 veces ( $n \geq 10$ ).

Tabla III  
PORCENTAJE DE PERSONAS PARA CADA CLASE PREDOMINANTE.

Clase	Predominancia		
	Nombre	$n \geq 1$	$n \geq 10$
□	g1	28,5 %	43,8 %
○	g2	17,9 %	4,1 %
△	g3	18,1 %	4,1 %
◇	g4	11,3 %	10,9 %
⊠	g5	8,1 %	31,5 %
+	-	15,8 %	5,4

Estos patrones de comportamiento pueden ser estudiados a lo largo del tiempo para ver la influencia de factores periódicos, como los días de la semana, los periodos de exámenes o los cuatrimestres en los que se divide el curso. Por ejemplo la figura 9 presenta los horarios habituales para cada persona detectada a lo largo de las distintas semana.

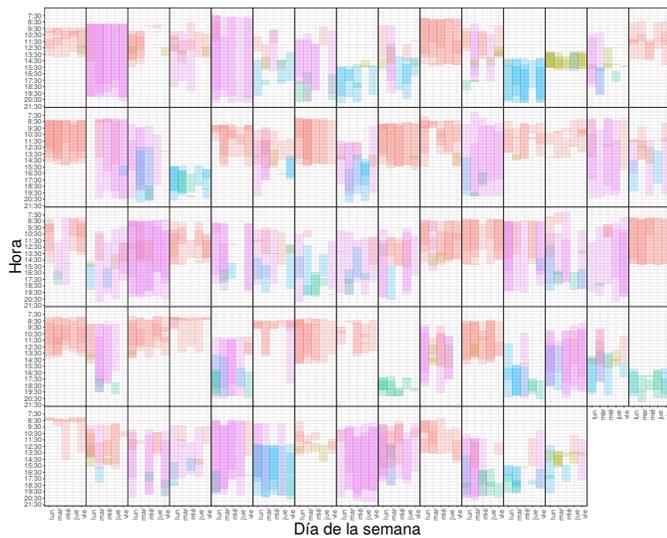


Figura 9. Horarios semanales de las 73 personas detectadas reincidentes más representativas. El color indica la clase en la que la que cada estancia ha sido clasificada. Cada visita se superpone con una capa de transparencia del 25%. La codificación de colores es la empleada en la Tabla III.

Esta información puede ser útil para decidir a que hora emplazar eventos maximizando la disponibilidad de los alumnos, escogiendo aquellas horas en las que habitualmente estén habitualmente a punto de irse de la facultad. Empleando la información del agrupador, se puede elegir intervalos de tiempos libres que beneficien a un tipo de visitante concreto, como se muestra en la Figura 10.

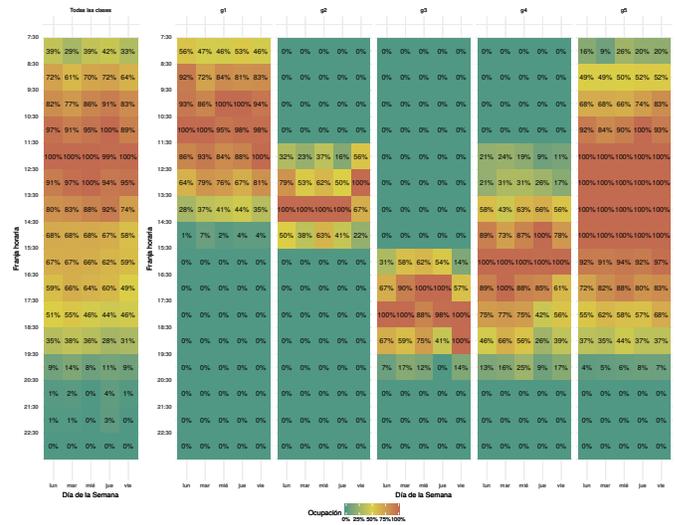


Figura 10. Disponibilidad de horarios para la realización de eventos en base a la asistencia a la escuela, tanto genérica como en base los distintos grupos de usuarios detectados. La ocupación se ha normalizado para cada día a una escala entre el 0 y el 100% del máximo diario.

### V. RESULTADOS

Se observa que la clase □ asignada a las personas que entran por la mañana y salen al medio día es la que ha sido asignada a un mayor porcentaje de gente, indicando que la mayoría de las personas que visitan la escuela lo hacen solo en horario de mañana. Además este patrón se muestra tanto en aquellas visitas puntuales, y se acentúa en las visitas reincidentes. Para los reincidentes, la segunda clase con mayor porcentaje (⊠) es aquella asignada a los visitantes que llegan por la mañana y se marchan por la tarde, constituyendo aproximadamente un tercio de los visitantes reincidentes. Un 5% de las visitas, se produce únicamente al mediodía (○) posiblemente por gente que únicamente emplea los servicios de comedores del edificio. Los visitantes que llegan al mediodía y se van por la tarde (◇) suponen un 10% de las visitas. Por último, sólo un 5% de los visitantes realizan su visita únicamente durante horario de tarde (△).

En cuanto a la disponibilidad de horario, en términos generales la mayor disponibilidad se presenta los jueves a partir de las 18:30. Para los distintos turnos, la asistencia por la mañana presentará mayor disponibilidad los martes de hasta las 11:30, en los turnos de tarde los jueves a partir 18:30. Estos rangos de horas y días son por tanto el momento idóneo para emplazar cualquier evento que no interrumpa la docencia habitual, obtenida en base a los patrones de comportamiento habituales de los alumnos reincidentes. O en caso de querer atraer a toda la audiencia posible, elegir dos periodos de tiempo que permitan la afluencia de ambos tipos de visitantes disjuntos, repitiendo el evento en los dos intervalos de tiempo obtenidos.

## VI. CONCLUSIONES

Si bien la información obtenida no es más que una muestra de la viabilidad de la captación de comunicaciones inalámbricas WiFi para la monitorización y extracción de patrones de comportamientos de las estancias de las personas en edificios, puede resultar una herramienta muy útil para la gestión eficiente de los recursos de dicho edificio. Así como para estudiar el impacto de nuevas medidas en los patrones de comportamiento de los visitantes.

A modo de ejemplo, en este artículo se han determinado los periodos de mayor disponibilidad de los alumnos para la posible asistencia a actividades no regladas, como charlas o conferencias, en base a los patrones de comportamiento extraídos de las visitas reincidentes.

La potencialidad de la aplicación de técnicas de inteligencia computacional y análisis de patrones a los datos obtenidos mediante la captación de comunicaciones inalámbricas permite dotar de fuentes de información baratas, fiables y anónimas a las ciudades inteligentes. Fuentes de datos que permitirán optimizar los recursos ajustándolos a los patrones de comportamiento aprendidos de las personas que los emplean.

La aplicabilidad del sistema *Mobywit* en multitud de escenarios de escenarios, supone también una futura línea de trabajo. El sistema puede ser empleado en cualquier punto geográfico donde se concentren masas de personas, y extraer información sobre el comportamiento de las mismas. Por ejemplo, ofreciendo tiempos de espera hasta ser atendidos en tareas administrativas, monitorizando los recintos habilitados para fumadores o el impacto de la calidad del menú del día en la afluencia de gente en los servicios de comedores.

## AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por los proyectos MOMOFES SPIP2017-02116 (Dirección General de Tráfico de España), EphemeCH TIN2014-56494-C4-3-P, DeepBio TIN2017-85727-C4-2-P y TEC2015-68752. Especial agradecimiento al cuerpo directivo de la ETSIT por la concesión del permiso para la implantación del nodo *Mobywit*.

## REFERENCIAS

- [1] W. J. Stanton, "Fundamentals of marketing," 1967.
- [2] G. Pan, G. Qi, W. Zhang, S. Li, Z. Wu, and L. T. Yang, "Trace analysis and mining for smart cities: issues, methods, and applications," *IEEE Communications Magazine*, vol. 51, no. 6, pp. 120–126, 2013.
- [3] R. Schneider, R. Patten, and J. Toole, "Case study analysis of pedestrian and bicycle data collection in us communities," *Transportation Research Record: Journal of the Transportation Research Board*, no. 1939, pp. 77–90, 2005.
- [4] R. Parisi, E. Di Claudio, G. Lucarelli, and G. Orlandi, "Car plate recognition by neural networks and image processing," in *Circuits and Systems, 1998. ISCAS'98. Proceedings of the 1998 IEEE International Symposium on*, vol. 3. IEEE, 1998, pp. 195–198.
- [5] M. C. Gonzalez, C. A. Hidalgo, and A.-L. Barabasi, "Understanding individual human mobility patterns," *Nature*, vol. 453, no. 7196, pp. 779–782, 2008.
- [6] K. Hashimoto, C. Kawaguchi, S. Matsueda, K. Morinaka, and N. Yoshiike, "People-counting system using multisensing application," *Sensors and Actuators A: Physical*, vol. 66, no. 1-3, pp. 50–55, 1998. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0924424797017159>

- [7] J. W. Davis and V. Sharma, "Robust background-subtraction for person detection in thermal imagery," in *CVPR Workshops*, 2004, p. 128.
- [8] K. Hashimoto, K. Morinaka, N. Yoshiike, C. Kawaguchi, and S. Matsueda, "People count system using multi-sensing application," in *Solid State Sensors and Actuators, 1997. TRANSDUCERS '97 Chicago., 1997 International Conference on*, vol. 2, Jun 1997, pp. 1291–1294 vol.2.
- [9] H. Celik, A. Hanjalic, and E. Hendriks, "Towards a robust solution to people counting," in *Image Processing, 2006 IEEE International Conference on*, Oct 2006, pp. 2401–2404.
- [10] A. Schofield, P. Mehta, and T. Stonham, "A system for counting people in video images using neural networks to identify the background scene," *Pattern Recognition*, vol. 29, no. 8, pp. 1421 – 1428, 1996. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/0031320395001638>
- [11] C.-H. Kuo and R. Nevatia, "How does person identity recognition help multi-person tracking?" in *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*. IEEE, 2011, pp. 1217–1224.
- [12] W. Zhao, R. Chellappa, P. J. Phillips, and A. Rosenfeld, "Face recognition: A literature survey," *ACM computing surveys (CSUR)*, vol. 35, no. 4, pp. 399–458, 2003.
- [13] M. L. Gras, "The legal regulation of cctv in europe," *Surveillance & Society*, vol. 2, no. 2/3, 2002.
- [14] T. Nicolai and H. Kenn, "About the relationship between people and discoverable bluetooth devices in urban environments," in *Proceedings of the 4th international conference on mobile technology, applications, and systems and the 1st international symposium on Computer human interaction in mobile technology*. ACM, 2007, pp. 72–78.
- [15] J. Weppner and P. Lukowicz, "Bluetooth based collaborative crowd density estimation with mobile phones," in *Pervasive Computing and Communications (PerCom), 2013 IEEE International Conference on*, March 2013, pp. 193–200.
- [16] A. Morrison, M. Bell, and M. Chalmers, "Visualisation of spectator activity at stadium events," in *Information Visualisation, 2009 13th International Conference*. IEEE, 2009, pp. 219–226.
- [17] Y. Chon, S. Kim, S. Lee, D. Kim, Y. Kim, and H. Cha, "Sensing wifi packets in the air: practicality and implications in urban mobility monitoring," in *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*. ACM, 2014, pp. 189–200.
- [18] W. Xi, J. Zhao, X.-Y. Li, K. Zhao, S. Tang, X. Liu, and Z. Jiang, "Electronic frog eye: Counting crowd using wifi," in *INFOCOM, 2014 Proceedings IEEE*, April 2014, pp. 361–369.
- [19] A. Fernández-Ares, M. García-Arenas, P. A. Castillo, and J. J. Merelo, "Impact of protests in the number of smart devices in streets: A new approach to analyze protesters behavior," in *International Conference on Smart Cities*. Springer, 2017, pp. 75–85.
- [20] A. Fernández-Ares, A. Mora, M. Arenas, P. García-Sánchez, G. Romero, V. Rivas, P. Castillo, and J. Merelo, "Studying real traffic and mobility scenarios for a smart city using a new monitoring and tracking system," *Future Generation Computer Systems*, vol. 76, pp. 163–179, 2017.
- [21] Hochbaum and Shmoys, "A best possible heuristic for the k-center problem," *Mathematics of Operations Research*, vol. 10, no. 2, pp. 180–184, 1985.



# Reduction of the Size of Datasets by using Evolutionary Feature Selection: the Case of Noise in a Modern City\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Javier Luque, Jamal Toutouh, Enrique Alba  
*Departamento de Lenguajes y Ciencias de la Computación*  
*Universidad de Málaga*  
Málaga, Spain  
javierluque@uma.es, {jamal, eat}@lcc.uma.es

**Abstract**—Smart city initiatives have emerged to mitigate the negative effects of a very fast growth of urban areas. Most of the population in our cities are exposed to high levels of noise that generate discomfort and different health problems. These issues may be mitigated by applying different smart cities solutions, some of them require high accurate noise information to provide the best quality of serve possible. In this study, we have designed a machine learning approach based on genetic algorithms to analyze noise data captured in the university campus. This method reduces the amount of data required to classify the noise by addressing a feature selection optimization problem. The experimental results have shown that our approach improved the accuracy in 20% (achieving an accuracy of 87% with a reduction of up to 85% on the original dataset).

**Index Terms**—Smart city, Genetic algorithm, Feature selection, Noise



# Studying Solutions of the $p$ -Median Problem for the Location of Public Bike Stations\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Christian Cintrano <i>E.T.S. Ingeniería Informática</i> University of Málaga Málaga, Spain cintrano@lcc.uma.es	Francisco Chicano <i>E.T.S. Ingeniería Informática</i> University of Málaga Málaga, Spain chicano@lcc.uma.es	Thomas Stützle <i>Université Libre de Bruxelles</i> Brussels, Belgium stuetzle@ulb.ac.be	Enrique Alba <i>E.T.S. Ingeniería Informática</i> University of Málaga Málaga, Spain eat@lcc.uma.es
--	--	---	---

**Abstract**—The use of bicycles as a means of transport is becoming more and more popular today, especially in urban areas, to avoid the disadvantages of individual car traffic. In fact, city managers react to this trend and actively promote the use of bicycles by providing a network of bicycles for public use and stations where they can be stored. Establishing such a network involves the task of finding best locations for stations, which is, however, not a trivial task. In this work, we examine models to determine the best location of bike stations so that citizens will travel the shortest distance possible to one of them. Based on real data from the city of Malaga, we formulate our problem as a  $p$ -median problem and solve it with a variable neighborhood search algorithm that was automatically configured with irace. We compare the locations proposed by the algorithm with the real ones used currently by the city council. We also study where new locations should be placed if the network grows.

**Index Terms**—Bike station location,  $p$ -Median problem, Variable neighborhood search

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 5: SESIÓN ESPECIAL:  
ALGORITMOS  
MULTIOBJETIVO

**Organizadores:**

ENRIQUE ALBA Y MARIANO LUQUE







# An Improvement Study of the Decomposition-based Algorithm Global WASF-GA for Evolutionary Multiobjective Optimization\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Sandra Gonzalez-Gallardo, Rubén Saborido, Ana B. Ruiz, Mariano Luque

*Department of Applied Economics (Mathematics)*

*University of Málaga*

Málaga, Spain

{sandragg, rsain, abruiz, mluque}@uma.es

**Abstract**—The convergence and the diversity of the decomposition-based evolutionary algorithm Global WASF-GA (GWASF-GA) relies on a set of weight vectors that determine the search directions for new non-dominated solutions in the objective space. Although using weight vectors whose search directions are widely distributed may lead to a well-diversified approximation of the Pareto front (PF), this may not be enough to obtain a good approximation for complicated PFs (discontinuous, non-convex, etc.). Thus, we propose to dynamically adjust the weight vectors once GWASF-GA has been run for a certain number of generations. This adjustment is aimed at re-calculating some of the weight vectors, so that search directions pointing to overcrowded regions of the PF are redirected toward parts with a lack of solutions that may be hard to be approximated. We test different parameters settings of the dynamic adjustment in optimization problems with three, five, and six objectives, concluding that GWASF-GA performs better when adjusting the weight vectors dynamically than without applying the adjustment.

**Index Terms**—Evolutionary multiobjective optimization, Decomposition-based algorithm, GWASF-GA, Weight vector



# Pruning Dominated Policies in Multiobjective Pareto Q-learning\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Lawrence Mandow, José-Luis Pérez-de-la-Cruz  
*Departamento de Lenguajes y Ciencias de la Computación*  
*Universidad de Málaga*  
Málaga, Spain  
{lawrence, perez}@lcc.uma.es

**Abstract**—The solution for a Multi-Objective Reinforcement Learning problem is a set of Pareto optimal policies. MPQ-learning is a recent algorithm that approximates the whole set of all Pareto-optimal deterministic policies by directly generalizing Q-learning to the multiobjective setting. In this paper we present a modification of MPQ-learning that avoids useless cyclical policies and thus improves the number of training steps required for convergence.

**Index Terms**—



# Estudio de escalabilidad de implementaciones multiobjetivo en problemas con muchos objetivos

Aurora Ramírez, Rafael Barbudo, José Raúl Romero, Sebastián Ventura

Dpto. Informática y Análisis Numérico, Universidad de Córdoba

{aramirez, rbarbudo, jrromero, sventura}@uco.es

**Resumen**—Los problemas de optimización de varios objetivos aparecen con frecuencia en aplicaciones reales, lo que ha llevado a la adaptación de la mayoría de las metaheurísticas existentes. El creciente interés en los problemas que presentan muchos objetivos también ha propiciado la aparición de nuevos métodos especializados. Para conseguir una mayor adopción de estas técnicas por parte de usuarios no familiarizados con el uso de metaheurísticas, es necesario que los nuevos desarrollos sean incluidos en librerías software que faciliten su configuración y adaptación. No obstante, la librería escogida puede repercutir en el rendimiento computacional, pues cada una sigue unos principios de diseño diferentes. Este trabajo analiza algunas de las implementaciones multiobjetivo disponibles en seis librerías con el propósito de estudiar su comportamiento frente a configuraciones de creciente complejidad y que incluyen problemas de hasta 50 objetivos. La experimentación realizada confirma que distintas implementaciones de un mismo algoritmo pueden presentar diferencias considerables en cuanto al tiempo de ejecución y la memoria consumida.

**Index Terms**—Optimización de muchos objetivos, metaheurísticas, librerías software

## I. INTRODUCCIÓN

Los problemas multiobjetivo han sido objeto frecuente de estudio en el campo de las metaheurísticas, pues son habitualmente aplicables en escenarios reales [1]. Este tipo de problemas requiere la definición de un conjunto de variables cuyo valor ha de determinarse, un conjunto de restricciones a cumplir y, al menos, dos objetivos independientes a optimizar [2]. La existencia de varios objetivos, a menudo contrapuestos, implica que la solución a un problema multiobjetivo no es única, sino que debe encontrarse un conjunto de soluciones donde cada una alcanza un compromiso distinto entre los objetivos. El estudio de enfoques bioinspirados para resolver problemas multiobjetivo ha dado lugar a algoritmos ya clásicos como NSGA-II y SPEA2, de los que es posible encontrar implementaciones en distintos lenguajes de programación [3].

Recientemente, la investigación en este campo se ha centrado en abordar la resolución de problemas con un número elevado de objetivos. Según la literatura, los denominados “problemas de muchos objetivos” (en inglés, *many-objective optimisation problems*) son aquellos que presentan cuatro o más objetivos [4]. Su resolución presenta nuevos retos, tales como el crecimiento exponencial del número de soluciones no dominadas o la ineficacia de operadores genéticos y técnicas de preservación de la diversidad [5]. De hecho, existen

estudios que demuestran el bajo rendimiento de algoritmos clásicos a la hora de resolver este tipo de problemas, así como el incremento en el coste computacional [6]. Estos hechos han propiciado el desarrollo de métodos especializados [7], así como la realización de estudios comparativos [8].

A pesar de que algunas librerías software están incorporando algunos de los algoritmos para optimización de muchos objetivos que van adquiriendo mayor relevancia, lo cierto es que aún no existe un gran número de implementaciones disponibles. Este hecho no solo dificulta su uso con fines comparativos, sino que limita su aplicación por parte de usuarios con menos experiencia en el campo de las metaheurísticas. Por otro lado, características como el lenguaje de programación y el diseño estructural de estas librerías podría suponer ciertas diferencias en el uso de los recursos computacionales, como el tiempo de ejecución y la memoria, que también deben considerarse ante la creciente complejidad tanto de los problemas como de los algoritmos.

En este contexto, este trabajo presenta un estudio preliminar del rendimiento de algoritmos multiobjetivo implementados en diferentes librerías software. Tras realizar un análisis de las implementaciones disponibles, se han elegido seis librerías Java: ECJ, EvA, JCLEC-MO, jMetal, MOEA Framework y Opt4J. El objetivo de la comparación es por tanto analizar el rendimiento desde una perspectiva puramente computacional, realizando mediciones del tiempo de ejecución y la memoria RAM consumida. Para ello se han seleccionado varios algoritmos y problemas de entre los disponibles en las librerías. Además, se ha estudiado la escalabilidad de las distintas implementaciones de NSGA-II respecto al número de individuos, generaciones y objetivos. Los resultados muestran que existen pequeñas diferencias entre las implementaciones cuando se consideran parámetros estándar, y que éstas se incrementan a medida que se consideran valores más extremos.

El resto del artículo se estructura como sigue. La sección II describe los algoritmos y problemas más utilizados en optimización multiobjetivo, mientras que la sección III recopila las principales librerías software que los implementan. La sección IV detalla la metodología diseñada para el estudio comparativo, cuyos resultados son analizados en la sección V. Finalmente, la sección VI presenta las conclusiones.

## II. OPTIMIZACIÓN CON MÚLTIPLES OBJETIVOS

Esta sección introduce los principales tipos de algoritmos multiobjetivo existentes, destacando aquellos especializados en

Trabajo financiado por los ministerios de Economía (TIN2017-83445-P) y de Educación (FPU13/01466), y fondos FEDER.

la optimización de muchos objetivos. Después se describen algunos de los problemas comúnmente utilizados para evaluar el rendimiento de estos algoritmos.

### II-A. Familias de algoritmos bioinspirados

Desde la publicación de VEGA, considerado el primer algoritmo evolutivo multiobjetivo [2], la aparición de nuevos algoritmos o mejoras sobre los ya propuestos ha sido constante [9]. En los inicios del área, los algoritmos iban siendo clasificados en generaciones [10]. Así, la conocida como *primera generación* se basa fuertemente en el concepto de dominancia y el uso de estrategias de nichos. La incorporación de mecanismos de elitismo es la principal característica de la *segunda generación*, a la que pertenecen SPEA2 y NSGA-II.

En el ámbito de la optimización de muchos objetivos, los algoritmos se clasifican atendiendo al enfoque que siguen para abordar los retos mencionados anteriormente [7]. En primer lugar, los algoritmos basados en descomposición definen un conjunto de pesos para establecer diferentes direcciones de búsqueda. MOEA/D es el algoritmo más conocido dentro de esta familia. Por otro lado, los algoritmos basados en indicadores utilizan una medida de rendimiento, como el hipervolumen, para guiar la búsqueda. IBEA fue el primer algoritmo de esta familia, donde también destacan HypE o SMS-EMOA. Otro conjunto de algoritmos se caracterizan por la adopción de criterios de dominancia relajados, como la  $\epsilon$ -dominancia utilizada tanto en algoritmos evolutivos ( $\epsilon$ -MOEA) como de optimización de partículas (OMOPSO). El uso de un conjunto de puntos de referencia es una técnica habitual para garantizar la diversidad en espacios de objetivos multidimensionales. En este grupo se encuentran algoritmos como NSGA-III y RVEA, entre otros. Finalmente, los métodos basados en preferencias, como WASF-GA o PICEA-g, permiten restringir la búsqueda a una zona de interés para el usuario. Los detalles de estos algoritmos pueden encontrarse en artículos de referencia como [7], [9].

### II-B. Problemas para el estudio del rendimiento

A la hora de comparar el rendimiento de distintos algoritmos, es frecuente utilizar problemas tipo o *benchmarks*. Por ejemplo, problemas tan conocidos como el de la mochila (*Knapsack Problem*, KP) o el viajante de comercio (*Travelling Salesman Problem*, TSP) han sido extendidos respecto a sus formulaciones originales para un único objetivo. Otro *benchmark* a destacar es LOTZ (*Leading Ones, Trailing Zeros*), un problema simple de codificación binaria con dos objetivos contrapuestos: maximizar el número de unos al comienzo del genotipo y maximizar el número de ceros al final.

Para codificación real existen varias familias de problemas cuyos frentes de Pareto óptimo presentan diferentes propiedades (discontinuidad en el frente, proximidad de óptimos locales, etc.). Además, algunas permiten establecer el número de objetivos que se desea optimizar, por lo que son especialmente útiles para estudiar la escalabilidad. Entre ellas cabe destacar ZDT, un conjunto de seis problemas con dos objetivos cada

uno [11], y DTLZ, un conjunto de nueve problemas cuyo número de objetivos es adaptable [12].

### III. IMPLEMENTACIONES DISPONIBLES EN LIBRERÍAS

La popularidad de las técnicas metaheurísticas ha llevado a la creación de librerías y *frameworks* software que dan soporte a la investigación y facilitan su aplicación práctica [3]. Este tipo de herramientas no solo contemplan la configuración y ejecución de los algoritmos y sus componentes, sino que también permiten adaptarlos a nuevos problemas.

La Tabla I muestra un listado de algunas librerías que incluyen soporte para la optimización multiobjetivo, indicando la última versión y su año de lanzamiento, el lenguaje de programación y los algoritmos que proporcionan<sup>1</sup>. Como puede observarse, entre ellas hay herramientas de propósito general muy conocidas, como HeuristicLab y ECJ. A pesar de su madurez, el número de implementaciones multiobjetivo que ofrecen se limita a los algoritmos evolutivos más populares. Otras librerías Java son Opt4J y EvA, las cuales disponen de mayor número y variedad de algoritmos. Más recientemente, han ido apareciendo librerías en Python, como DEAP (especializada en algoritmos distribuidos) y PyGMO (especializada en algoritmos paralelos), si bien el número de algoritmos multiobjetivo en ambas es aún reducido.

ParadisEO-MOEO y JCLEC-MO se asemejan en cuanto a su estructura, pues ambas librerías disponen de un módulo específico para optimización multiobjetivo. Por un lado, ParadisEO ha sido posiblemente la librería más popular de entre las desarrolladas en C++, si bien lleva tiempo sin ser actualizada. Por otro lado, JCLEC-MO ofrece un mayor conjunto de algoritmos, incluyendo algunos especialmente indicados para problemas de muchos objetivos.

Finalmente, también es posible encontrar librerías especializadas en optimización multiobjetivo. La primera de ellas fue PISA, si bien se trata de un proyecto ya abandonado. jMetal y MOEA Framework, ambas desarrolladas en Java, destacan por sus continuas actualizaciones y su amplio catálogo de algoritmos. Dos proyectos muy recientes y activos son PlatEMO y Platypus, desarrollados en Matlab y Python, respectivamente.

### IV. METODOLOGÍA EXPERIMENTAL

Para el estudio comparativo de implementaciones multiobjetivo se han seleccionado las seis librerías Java detalladas en la Tabla I. La elección de un único lenguaje de programación facilita la comparación pues evita posibles diferencias debidas al proceso de compilación. Además, estas librerías cuentan con, al menos, dos algoritmos en común, lo cual reduce la posibilidad de alterar el rendimiento debido a la diferencia de implementación entre desarrollos propios y nativos. Tan solo ha sido necesario implementar algunos problemas para disponer de un conjunto lo suficientemente variado, así como operadores genéticos estándar.

Tras analizar las herramientas, se han planteado dos experimentos. El primero tiene como objetivo estudiar distintas

<sup>1</sup>Las posibles variantes de dichos algoritmos no son mostradas por motivos de espacio. El lector es remitido a la documentación de cada herramienta.



Tabla I  
LIBRERÍAS Y ALGORITMOS DISPONIBLES PARA OPTIMIZACIÓN MULTIOBJETIVO

Librería	Versión	Año	Lenguaje	Principales algoritmos
DEAP	1.2.2	2017	Python	CMAES-MO, NSGA-II, SPEA2
ECJ	26	2018	Java	NSGA-II, NSGA-III, SPEA2
EvA	2.2	2015	Java	CMAES-MO, MOGA, NSGA, NSGA-II, PESA, PESA2, SPEA, SPEA2
HeuristicLab	3.3.15	2018	C#	CMAES-MO, NSGA-II
JCLEC-MO	1.0	2018	Java	$\epsilon$ -MOEA, GrEA, HypE, IBEA, MOCHC, MOEA/D, OMOPSO, NSGA-II, NSGA-III, PAES, PAR, RVEA, SMS-EMOA, SMPSO, SPEA2
jMetal	5.4	2017	Java	AbYSS, CellIDE, dMOPSO, GDE3, GWASF-GA, IBEA, MOCell, MOCHC, MOEA/D, MOEADD, MOMB, MOMB-II, NSGA-II, NSGA-III, OMOPSO, PAES, PESA2, SMS-EMOA, SMPSO, SPEA2, WASF-GA
MOEA Framework	2.12	2017	Java	CMAES-MO, DBEA, $\epsilon$ -MOEA, GDE3, IBEA, MOEA/D, MSOPS, NSGA-II, NSGA-III, OMOPSO, PAES, PESA2, RVEA, SMPSO, SMS-EMOA, SPEA2, VEGA
Opt4J	3.1.4	2015	Java	NSGA-II, OMOPSO, SMS-EMOA, SPEA2
PaGMO/PyGMO	2.8	2018	C++/Python	MOEA/D, NSGA-II
ParadisEO-MOEO	2.0.1	2012	C++	MOGA, IBEA, NSGA, NSGA-II, SPEA2
PlatEMO	1.5	2017	Matlab	AGE-II, dMOPSO, $\epsilon$ -MOEA, GDE3, GrEA, HypE, I-DBEA, IBEA, LMEA, MOEA/D, MOMB-II, MOPSO, MSOPS-II, NSGA-II, NSGA-III, PICEA-g, PSEA-II, RPEA, RVEA, SMPSO, SMS-EMOA, SPEA2, Two_Arch2
Platypus	1.0.2	2018	Python	$\epsilon$ -MOEA, GDE3, IBEA, MOEA/D, NSGA-II, NSGA-III, OMOPSO, SMPSO, SPEA2.
PISA	-	2009	C	$\epsilon$ -MOEA, FEMO, HypE, IBEA, MSOPS, NSGA-II, SEMO2, SHV, SPAM, SPEA2

combinaciones de algoritmos y problemas, donde estos últimos varían en cuanto al tipo de codificación y al número de objetivos. La Tabla II muestra la configuración propuesta, donde el número entre paréntesis representa el número de problema dentro de la familia correspondiente. Para las tres librerías que disponen de un número menor de algoritmos se ha seleccionado un número mayor de problemas. En cuanto a las tres últimas librerías, se han seleccionado algoritmos representativos de distintas familias. En el caso de MOEA/D, únicamente se han considerado problemas de optimización real debido a que es el tipo de problema asumido en jMetal. Igualmente, la generación automática de los pesos se limita a problemas biobjetivo. Por ser un algoritmo de partículas, OMOPSO también queda restringido a problemas de optimización real. La Tabla III recoge los valores de los parámetros, tanto generales como específicos de cada algoritmo.

Tabla II  
ALGORITMOS Y PROBLEMAS SELECCIONADOS

Algoritmo	Problema		
	2 obj.	4 obj.	6 obj.
<i>ECJ, EvA, Opt4J</i>			
NSGA-II	LOTZ, ZDT (1, 4)	KP	DTLZ (1, 2, 4)
SPEA2	LOTZ, ZDT (1, 4)	KP	DTLZ (1, 2, 4)
<i>JCLEC-MO, jMetal, MOEA Framework</i>			
IBEA	LOTZ	KP	DTLZ (1, 2)
MOEA/D	ZDT (1, 4)		DTLZ (1, 2)
OMOPSO	ZDT (1, 4)		DTLZ (1, 2)
NSGA-II	LOTZ	KP	DTLZ (1, 2)

El segundo experimento pretende analizar la escalabilidad de las implementaciones en base a tres factores: el tamaño de la población (100, 500, 1000), el número de generaciones (100, 500, 1000) y el número de objetivos (2, 5, 10, 25, 50). Estas configuraciones serán identificadas como Px-Gy-Oz, donde P representa el tamaño de la población, G, las generaciones y O, los objetivos. El algoritmo escogido es NSGA-II, ya que

está presente en todas las librerías y no presenta parámetros adicionales. Puesto que se desea variar el número de objetivos, se ha seleccionado DTLZ1 como problema a resolver. Los operadores genéticos y sus probabilidades se configuran de acuerdo a los valores mostrados en la Tabla III.

Tabla III  
CONFIGURACIÓN DE PARÁMETROS

Parámetro	Valor
Parámetros comunes	
Tamaño de la población	100
Número de generaciones	100
Probabilidad de cruce	0,9
Probabilidad de mutación	0,1 (1/longitud_genotipo)
Operador de cruce	1-Point (binario), SBX (real)
Operador de mutación	Bit flip (binario), Polynomial (real)
SPEA2	
Tamaño de la población (P)	50
Tamaño del archivo (A)	50
Selector de padres	Torneo binario
Parámetro k	$\sqrt[3]{P + A}$
MOEA/D	
Tamaño de vecindad ( $\tau$ )	10
Máx. Núm. Reemplazos (nr)	2
Modo de evaluación	Tchebycheff
Generación de pesos	Uniforme
IBEA	
Selector de padres	Torneo binario
Indicador para evaluación	Hipervolumen
Parámetro $\kappa$	0,05
Parámetro $\rho$	2
OMOPSO	
Tamaño del archivo	100
Parámetro $\epsilon$	0,0075

En ambos experimentos se ha utilizado Syrupy<sup>2</sup> como herramienta profiler para medir el tiempo de ejecución y el consumo de memoria a intervalos regulares. Dichos intervalos se han establecido en base a ejecuciones previas con el fin de

<sup>2</sup><https://github.com/jeetsukumaran/Syrupy>

obtener un mínimo de 30 muestras para cada configuración. La experimentación se ha realizado en una máquina con Debian 8, ocho núcleos Intel Core i7-2600, CPU a 3,4 GHz y 16 GB de memoria RAM. En el caso del primer experimento, cada configuración ha sido ejecutada cinco veces en un único núcleo para evitar posibles interferencias. Además, se ha alternado el orden de ejecución de cada librería para mantener condiciones similares respecto al arranque de la JVM. En el segundo experimento, cada configuración ha sido lanzada seis veces utilizando dos núcleos para que el experimento no tuviese una duración excesiva. No obstante, las configuraciones también se planificaron de forma que no siempre las mismas librerías estuviesen ejecutando en paralelo a fin de reducir el sesgo lo más posible. Tras obtener el tiempo medio de ejecución de cada configuración, se ha aplicado el test de Friedman para analizar si existen diferencias significativas entre aquellas librerías para las que se ejecutaron los mismos algoritmos y problemas. Es decir, para el primer experimento se analizan dos grupos por separado, uno formado por ECJ, EvA y Opt4J, y otro formado por JCLEC-MO, jMetal y MOEA Framework. En caso de encontrar diferencias significativas, se aplica el post-procedimiento de Holm. Además, se ha ejecutado el test Cliff's Delta para analizar el tamaño del efecto, esto es, la magnitud de la diferencia observada.

## V. RESULTADOS Y DISCUSIÓN

En esta sección se presentan los resultados obtenidos para cada uno de los experimentos planteados. Por motivos de espacio, solo los resultados más relevantes son discutidos.

### V-A. Comparación de algoritmos y problemas

Las Tablas IV y V muestran los tiempos medios de ejecución y la desviación estándar para los dos grupos de librerías. La ejecución más rápida (0,24 s) se corresponde con la resolución de DTLZ2 con MOEA/D en jMetal. Por el contrario, el problema de la mochila con NSGA-II en ECJ es la combinación que más tiempo ha necesitado (4,88 s).

En el primer grupo de librerías (Tabla IV), ECJ es la que requiere menos tiempo, empleando más de un segundo en solo cuatro configuraciones. EvA es la librería que reporta tiempos de ejecución más altos, siempre por encima de un segundo, mientras que Opt4J mantiene tiempos más estables, entre 0,5 y 1,5 s. Para confirmar si estas diferencias son significativas, se ha aplicado el test de Friedman, donde la hipótesis nula establece que todas las librerías tienen un rendimiento similar. El valor del estadístico de *Iman and Daveport*,  $z$ , es 30,71, mientras que el valor crítico de acuerdo a una distribución  $F$  con 2 y 30 grados de libertad es igual a 5,39 ( $\alpha = 0,01$ ). Dado que  $z$  es mayor que el valor crítico, la hipótesis nula puede ser rechazada. El test de Holm devuelve un  $p$ -value igual a 0,05, lo que confirma que ECJ es significativamente superior a EvA, pero equivalente a Opt4J. En cuanto al efecto del tamaño, el test Cliff's Delta indica que la diferencia en tiempo entre las tres librerías es siempre amplia (*large*).

En el segundo grupo de librerías (JCLEC-MO, jMetal y MOEA Framework), IBEA es el algoritmo más costoso,

Tabla IV  
TIEMPO DE EJECUCIÓN EN SEGUNDOS PARA EL PRIMER GRUPO DE LIBRERÍAS (EXPERIMENTO 1)

Configuración	ECJ	EvA	Opt4J
NSGA-II - LOTZ(2)	0,245 ± 0,014	1,443 ± 0,037	0,773 ± 0,050
NSGA-II - ZDT1(2)	0,299 ± 0,015	1,827 ± 0,019	0,785 ± 0,056
NSGA-II - ZDT4(2)	0,295 ± 0,017	1,537 ± 0,014	0,765 ± 0,068
NSGA-II - ZDT6(2)	0,284 ± 0,034	1,466 ± 0,023	0,758 ± 0,058
NSGA-II - KP(4)	4,879 ± 0,022	1,587 ± 0,041	1,142 ± 0,076
NSGA-II - DTLZ1(6)	0,344 ± 0,021	1,658 ± 0,043	0,896 ± 0,067
NSGA-II - DTLZ2(6)	0,336 ± 0,022	1,803 ± 0,040	0,900 ± 0,043
NSGA-II - DTLZ4(6)	0,351 ± 0,034	1,834 ± 0,039	0,922 ± 0,110
SPEA2 - LOTZ(2)	0,444 ± 0,017	1,445 ± 0,022	0,609 ± 0,038
SPEA2 - ZDT1(2)	0,368 ± 0,028	2,684 ± 0,032	0,999 ± 0,087
SPEA2 - ZDT4(2)	0,291 ± 0,022	1,380 ± 0,029	1,020 ± 0,060
SPEA2 - ZDT6(2)	0,300 ± 0,021	1,385 ± 0,047	0,735 ± 0,032
SPEA2 - KP(4)	3,219 ± 0,033	1,736 ± 0,105	1,173 ± 0,065
SPEA2 - DTLZ1(6)	0,959 ± 0,050	1,646 ± 0,107	1,633 ± 0,236
SPEA2 - DTLZ2(6)	1,442 ± 0,023	2,702 ± 0,038	1,583 ± 0,070
SPEA2 - DTLZ4(6)	1,435 ± 0,088	2,897 ± 0,059	1,699 ± 0,103
Friedman (ranking)	<b>1,250</b>	2,875	1,875
Holm ( $\alpha/i$ )	-	0,025	0,050

Tabla V  
TIEMPO DE EJECUCIÓN EN SEGUNDOS PARA EL SEGUNDO GRUPO DE LIBRERÍAS (EXPERIMENTO 1)

Configuración	JCLEC-MO	jMetal	MOEA Fram.
NSGA-II - LOTZ(2)	0,410 ± 0,009	0,624 ± 0,023	0,328 ± 0,018
NSGA-II - KP(4)	0,519 ± 0,027	0,558 ± 0,042	0,374 ± 0,016
NSGA-II - DTLZ1(6)	0,537 ± 0,028	0,540 ± 0,066	0,444 ± 0,011
NSGA-II - DTLZ2(6)	0,587 ± 0,064	0,595 ± 0,055	0,389 ± 0,008
IBEA - LOTZ(2)	4,754 ± 0,037	1,288 ± 0,039	0,844 ± 0,019
IBEA - KP(4)	3,012 ± 0,036	1,678 ± 0,142	1,036 ± 0,029
IBEA - DTLZ1(6)	1,829 ± 0,030	2,556 ± 0,034	1,254 ± 0,011
IBEA - DTLZ2(6)	1,843 ± 0,018	2,538 ± 0,032	1,285 ± 0,007
MOEA/D - ZDT1(2)	0,429 ± 0,018	0,337 ± 0,020	0,458 ± 0,008
MOEA/D - ZDT4(2)	0,413 ± 0,030	0,277 ± 0,010	0,414 ± 0,010
MOEA/D - DTLZ1(2)	0,380 ± 0,022	0,260 ± 0,013	0,434 ± 0,023
MOEA/D - DTLZ2(2)	0,492 ± 0,035	0,236 ± 0,004	0,412 ± 0,016
OMOPSO - ZDT1(2)	0,556 ± 0,034	0,412 ± 0,050	1,269 ± 0,040
OMOPSO - ZDT4(2)	0,530 ± 0,043	0,284 ± 0,010	1,117 ± 0,032
OMOPSO - DTLZ1(2)	0,663 ± 0,009	0,484 ± 0,042	1,510 ± 0,016
OMOPSO - DTLZ2(2)	0,715 ± 0,035	1,466 ± 0,086	2,139 ± 0,072
Friedman (ranking)	2,125	<b>1,938</b>	<b>1,938</b>

requiriendo varios segundos de ejecución. La diferencia con respecto al resto de algoritmos es más evidente en JCLEC-MO y jMetal, especialmente cuando se resuelven problemas combinatorios. Para este conjunto de librerías, el test de Friedman no encuentra diferencias significativas. De hecho, el test Cliff's Delta siempre cataloga las diferencias entre cada pareja de librerías como insignificante (*negligible*), salvo entre jMetal y JCLEC-MO, que es pequeña (*small*).

Dado que todas estas configuraciones son simples y se ejecutan en pocos segundos, tan solo se pueden realizar algunas apreciaciones respecto a la memoria RAM consumida. Las seis librerías Java analizadas consumen un mínimo de 12.000 KB en cada ejecución. EvA y Opt4J son las dos librerías que muestran un comportamiento más estable, con un máximo de 56.459 KB y 126.084 KB de media, respectivamente. Entre el resto, el uso máximo de memoria es más disperso llegando a presentar "picos" de más de 100.000 KB en JCLEC-MO (76.130 KB de media), jMetal (88.326 KB) y MOEA Framework (89.005 KB), y más de 500.000 KB en ECJ (149.265 KB) cuando se resuelve el problema de la mochila.

Valorando los resultados del primer experimento en global,



todas las librerías presentan unos requisitos de tiempo y memoria asumibles ante un escenario de uso normal. Aún así, y a pesar de que las configuraciones probadas son poco exigentes, se perciben ciertas diferencias. En concreto, no todas las librerías responden igual ante la ejecución de un mismo algoritmo en problemas de distinta naturaleza (combinatorios frente a optimización real). En este sentido, los problemas combinatorios son más costosos, aún cuando el número de objetivos es inferior al considerado para los problemas DTLZ. Esto puede deberse a que la evaluación requiere la interpretación del genotipo, frente al uso directo de las variables reales. Por otro lado, la formulación concreta de los diferentes problemas ZDT no parece tener una gran influencia en el tiempo, mientras que sí se observan algunas diferencias respecto a los problemas DTLZ (véase por ejemplo OMOPSO en jMetal y MOEA Framework, o SPEA2 en ECJ y EvA). Respecto a los algoritmos, NSGA-II suele ser el más rápido en la mayoría de librerías. La única excepción parece ser la implementación de MOEA/D en JCLEC-MO y jMetal, si bien hay que considerar que este algoritmo solo ha sido probado con problemas biobjetivo de codificación real.

#### V-B. Test de escalabilidad

El segundo experimento, donde se ejecutan configuraciones con hasta 50 objetivos, permite detectar mayores diferencias entre las librerías. La Tabla VI muestra los tiempos mínimos y máximos medios, con su desviación estándar, para cada tamaño de población. También se incluye el ranking obtenido con el test de Friedman. Cabe señalar que los tiempos mínimos y máximos corresponden, por lo general, con las configuraciones P100-G100-O2 y P1000-G5000-O50. Las excepciones son algunos tiempos mínimos en Opt4J, JCLEC-MO y jMetal, que se consiguen para cinco objetivos. No obstante, los valores son muy similares a los obtenidos para dos objetivos, por lo que pueden deberse a pequeñas fluctuaciones en la carga de la máquina. En base a estos resultados, ECJ es la librería que mejor responde ante configuraciones más exigentes, seguida de MOEA Framework, si bien el test de Holm no indica la existencia de diferencias significativas entre ambas. Les siguen jMetal y JCLEC-MO, si bien cabe señalar que JCLEC-MO responde algo mejor que jMetal ante el aumento del número de objetivos. Lo mismo ocurre si se comparan las dos librerías más lentas según este estudio, pues aunque Opt4j y EvA reportan tiempos mínimos similares, Opt4J escala mejor.

Por otro lado, los datos extraídos muestran que el incremento en el tiempo de ejecución no depende únicamente del número de generaciones. Por ejemplo, configuraciones con 1000 generaciones y dos objetivos pueden requerir menos tiempo de cómputo que configuraciones con 500 generaciones y 50 objetivos. Aunque hay algunas excepciones, sí se aprecia un incremento lineal cuando dos de los parámetros son fijados y el otro aumenta progresivamente. Los dos parámetros más determinantes son el número de generaciones y el número de objetivos, especialmente cuando se consideran valores superiores a 500 y 10, respectivamente. A modo de ejemplo, la Figura 1 muestra el tiempo medio de ejecución para las

distintas combinaciones de objetivos y generaciones, fijando el tamaño de población en 1000 (el valor más alto probado). Para facilitar la comparación entre librerías, se ha mantenido la misma escala respecto al tiempo. A excepción de EvA, las librerías presentan una tendencia similar y no suelen requerir más de 30 minutos por ejecución.

Con respecto al consumo de memoria, el alto número de combinaciones probadas permite obtener mayores diferencias. A modo de resumen, la Tabla VII recoge el valor mínimo y máximo de memoria registrado para cada librería. Como puede verse, no existen grandes diferencias en cuanto a los valores mínimos, pero sí en los máximos alcanzados. También se muestra el porcentaje de veces que cada librería obtiene el mínimo y máximo global para las 60 combinaciones probadas. En este caso, ECJ y Opt4J son las librerías que menor y mayor memoria consumen, respectivamente.

Este test de escalabilidad confirma que las implementaciones Java actuales pueden sufrir una degradación considerable en su rendimiento si se las somete a configuraciones extremas. Aunque quizás no sean los valores más habituales en la práctica, también debe considerarse que NSGA-II no es de los algoritmos más costosos y que el problema es sintético. En una aplicación real, donde fuese necesario ejecutar algoritmos específicos para problemas de muchos objetivos cuya evaluación fuese costosa, la elección de una implementación u otra podría ser determinante. Entre las librerías analizadas, EvA y Opt4J presentan mayores problemas para controlar el tiempo y la memoria, respectivamente. Por el contrario, ECJ y MOEA Framework presentan el mejor rendimiento considerando ambos factores a la vez, ya que tanto jMetal como JCLEC-MO experimentan mayores oscilaciones de memoria.

## VI. CONCLUSIONES

Este trabajo ha presentado una comparativa experimental de implementaciones de algoritmos multiobjetivo disponibles en seis librerías Java con el fin de analizar sus requisitos de tiempo y memoria. Los distintos algoritmos han sido ejecutados considerando configuraciones que difieren en el tipo de problema, el número de objetivos, el número de generaciones y el tamaño de la población. Los dos experimentos realizados indican que estos parámetros afectan en mayor o menor medida a todas las librerías. Para un uso estándar, las diferencias son poco apreciables y están condicionadas a la complejidad del algoritmo o del problema a resolver. Sin embargo, si se necesitan valores elevados para los parámetros anteriores, es conveniente analizar la forma en que cada librería implementa el algoritmo, pues las diferencias pueden ser notables. En este sentido, este estudio puede extenderse para abarcar un mayor número de librerías, algoritmos y problemas. Asimismo, sería interesante analizar la capacidad de las distintas librerías para paralelizar la evaluación de soluciones.

## REFERENCIAS

- [1] T. Stewart, O. Bandte, H. Braun, N. Chakraborti, M. Ehrgott, M. Göbelt, Y. Jin, H. Nakayama, S. Poles, and D. Di Stefano, "Real-World Applications of Multiobjective Optimization," in *Multiobjective Optimization*, vol. 5252 of *LNCS*, pp. 285–327, Springer Berlin Heidelberg, 2008.

Tabla VI  
 TIEMPOS MÍNIMOS Y MÁXIMOS EN SEGUNDOS (EXPERIMENTO 2)

Librería	P = 100		P = 500		P = 1000		Ranking
	Min.	Máx.	Min.	Máx.	Min.	Máx.	
ECJ	0,34 ± 0,04	14,37 ± 0,92	0,79 ± 0,05	170,61 ± 2,44	2,73 ± 0,09	589,33 ± 3,58	1,00
EvA	1,79 ± 0,02	226,77 ± 2,25	5,74 ± 0,62	3830,01 ± 94,69	16,38 ± 0,49	16030,96 ± 512,88	6,00
JCLEC-MO	0,64 ± 0,07	30,55 ± 0,58	3,25 ± 0,10	475,77 ± 4,83	11,86 ± 0,07	1611,35 ± 91,90	4,11
jMetal	0,58 ± 0,06	30,74 ± 1,21	2,64 ± 0,07	576,81 ± 3,86	9,01 ± 0,17	2237,61 ± 30,34	3,35
MOEA Framework	0,37 ± 0,01	19,26 ± 0,21	1,43 ± 0,08	339,96 ± 1,59	4,27 ± 0,14	1284,00 ± 7,17	2,02
Opt4J	0,93 ± 0,08	39,18 ± 0,68	4,12 ± 0,09	533,96 ± 6,95	13,98 ± 0,31	1743,74 ± 12,82	4,52

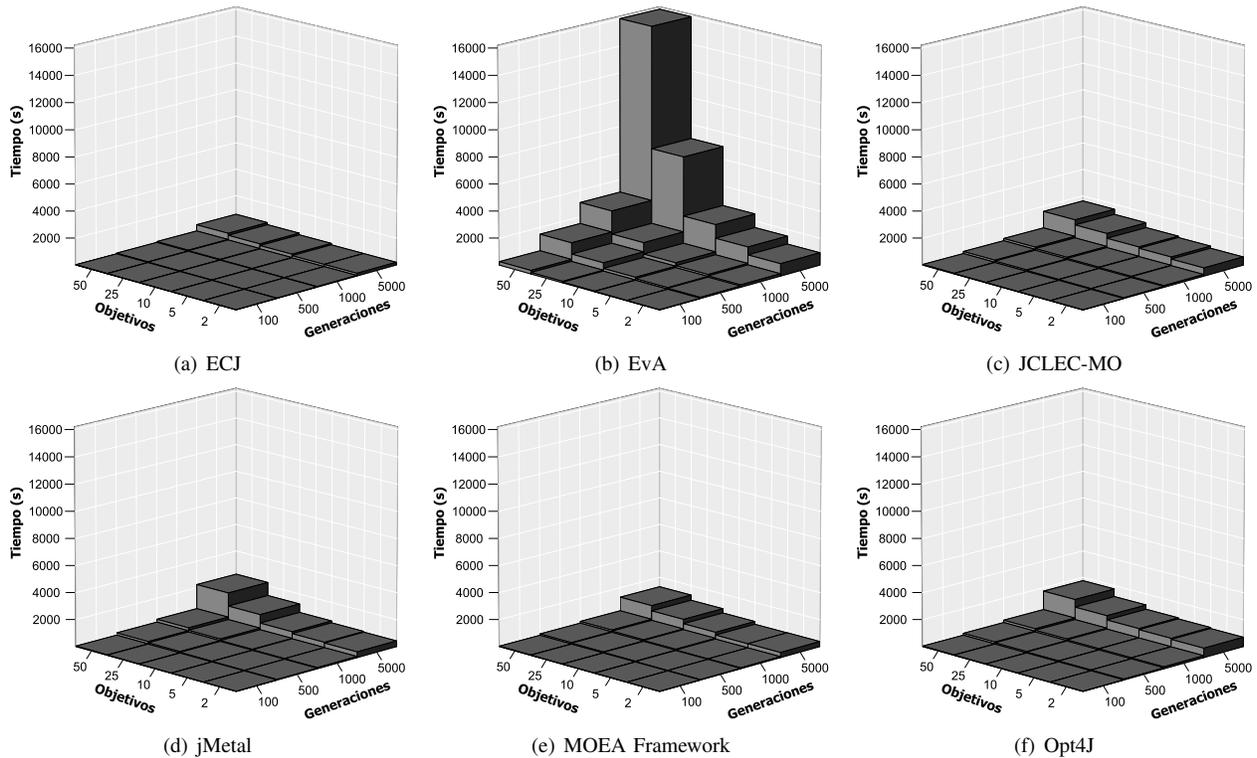


Figura 1. Variación en el tiempo de ejecución de NSGA-II para una población de 1000 individuos (experimento 2)

 Tabla VII  
 RESUMEN DEL CONSUMO DE MEMORIA (EXPERIMENTO 2)

Librería	Valores (KB)		Porcentajes	
	Min.	Máx.	Min.	Máx.
ECJ	123960	2064160	26,67	0,00
EvA	111080	1676000	15,00	0,00
JCLEC-MO	123840	6450680	13,33	0,00
jMetal	124080	14485480	23,33	23,33
MOEA Framework	123760	2589000	15,00	0,00
Opt4J	124480	3909920	6,67	76,67

- [2] C. A. Coello Coello, G. B. Lamont, and D. A. Van Veldhuizen, *Evolutionary Algorithms for Solving Multi-Objective Problems*. Springer, 2nd ed., 2007.
- [3] J. A. Parejo, A. Ruiz-Cortés, S. Lozano, and P. Fernández, "Metaheuristic optimization frameworks: a survey and benchmarking," *Soft Comput.*, vol. 16, no. 3, pp. 527–561, 2012.
- [4] S. Chand and M. Wagner, "Evolutionary many-objective optimization: A quick-start guide," *Surv. Oper. Res. Manag. Sci.*, vol. 20, no. 2, pp. 35–42, 2015.
- [5] A. López Jaimes and C. A. Coello Coello, *Springer Handbook of Computational Intelligence*, ch. Many-Objective Problems: Challenges and Methods, pp. 1033–1046. Springer Berlin Heidelberg, 2015.
- [6] V. Khare, X. Yao, and K. Deb, "Performance Scaling of Multi-objective Evolutionary Algorithms," in *Proc. 2nd Int. Conf. Evolutionary Multi-Criterion Optimization*, pp. 376–390, 2003.
- [7] B. Li, J. Li, K. Tang, and X. Yao, "Many-Objective Evolutionary Algorithms: A Survey," *ACM Comput. Surv.*, vol. 48, no. 1, pp. 13:1–35, 2015.
- [8] J. Maltese, B. M. Ombuki-Berman, and A. P. Engelbrecht, "A Scalability Study of Many-Objective Optimization Algorithms," *IEEE T Evolut. Comput.*, vol. 22, no. 1, pp. 79–96, 2018.
- [9] A. Zhou, B.-Y. Qu, H. Li, S.-Z. Zhao, P. N. Suganthan, and Q. Zhang, "Multiobjective evolutionary algorithms: A survey of the state of the art," *Swarm Evolut. Comput.*, vol. 1, no. 1, pp. 32–49, 2011.
- [10] C. A. Coello Coello, "Evolutionary Multiobjective Optimization: Current and Future Challenges," in *Advances in Soft Computing*, pp. 243–256, Springer London, 2003.
- [11] E. Zitzler, K. Deb, and L. Thiele, "Comparison of Multiobjective Evolutionary Algorithms: Empirical Results," *Evolut. Comput.*, vol. 8, no. 2, pp. 173–195, 2000.
- [12] K. Deb, L. Thiele, M. Laumanns, and E. Zitzler, *Scalable Test Problems for Evolutionary Multiobjective Optimization*, ch. Evolutionary Multiobjective Optimization, pp. 105–145. Springer London, 2005.



# Algoritmo Evolutivo con División del Espacio de los Objetivos en base a la Solución Nadir: Un Estudio Comparativo sobre el Problema de la Mochila 0/1 Bi-Objetivo

1<sup>st</sup> Máximo Méndez

*Instituto Universitario de Sistemas Inteligentes (SIANI)*  
*Universidad de Las Palmas de Gran Canaria (ULPGC)*  
España

maximo.mendez@ulpgc.es

2<sup>nd</sup> Daniel Alejandro Rossit

*Departamento de Ingeniería*  
*CONICET, Universidad Nacional del Sur (UNS)*  
Argentina

daniel.rossit@uns.edu.ar

3<sup>rd</sup> Mariano Frutos

*Departamento de Ingeniería*  
*CONICET, Universidad Nacional del Sur (UNS)*  
Argentina

mfrutos@uns.edu.ar

4<sup>th</sup> Begoña González

*Instituto Universitario de Sistemas Inteligentes (SIANI)*  
*Universidad de Las Palmas de Gran Canaria (ULPGC)*  
España

bego.landin@ulpgc.es

**Resumen**—Este trabajo presenta un algoritmo evolutivo multiobjetivo (AEMO) el cual divide el espacio de los objetivos, en varias regiones utilizando la solución Nadir calculada en cada generación del algoritmo. Para la clasificación de las soluciones de las distintas regiones en frentes no-dominados, se utilizan diferentes estrategias de optimización de las funciones objetivo. La idea es intensificar la diversidad del frente de soluciones no-dominadas alcanzado. El algoritmo propuesto (NSGA-II/OSD) se implementa sobre el algoritmo NSGA-II y se ensaya sobre el Problema de la Mochila 0/1 Bi-Objetivo (MOKP-0/1) bien conocido en la comunidad multiobjetivo. Con dos objetivos, este problema es de difícil resolución para un AEMO dado el elevado número de soluciones superpuestas (overlapping solutions) que se generan durante su evolución. El método propuesto ofrece muy buen desempeño cuando es comparado con los algoritmos NSGA-II y MOEA/D muy reconocidos ambos en la literatura especializada.

**Index Terms**—Optimización, Algoritmos Evolutivos Multiobjetivo, Dominancia de Pareto, MOKP0/1, NSGA-II, MOEA/D.

## I. INTRODUCCIÓN

Un problema de optimización multiobjetivo (POM) es aquel que corresponde a una cierta realidad industrial, económica o de otra índole y sobre el que un decisor desea optimizar varios objetivos usualmente en conflicto entre sí. Cuando se resuelve un POM de complejidad difícil, métodos metaheurísticos son muy apropiados. Estos métodos no garantizan obtener el frente exacto de soluciones no-dominadas, pero sí un conjunto aproximado.

La segunda generación de algoritmos evolutivos multiobjetivo (AEMOs), ha demostrado obtener excelentes resultados resolviendo POM [1]. De naturaleza estocástica, los AEMOs están basados en el concepto de población de soluciones lo

que les proporciona gran destreza para encontrar múltiples soluciones no-dominadas en espacios de soluciones de diversa naturaleza. NSGA-II [2] y MOEA/D [12] son dos AEMOs muy reconocidos en la comunidad científica multiobjetivo. El primero, utiliza una clasificación de rangos por dominancia como mecanismo de convergencia, mientras que crowding-distance es el mecanismo usado para diversificar las soluciones. El segundo, funciona descomponiendo el POM en un número de subproblemas escalares o mono-objetivos que son resueltos todos a la misma vez mediante la evolución de una población de soluciones. Algunos trabajos recientes describen dificultades en cuanto a la especificación del punto de referencia en MOEA/D [6], [7], [9], [11]. Trabajos con AEMOs que incluyan un sub-división del espacio de los objetivos como la propuesta en este trabajo son muy escasos, sólo hemos encontrado [8], [10].

El problema de la mochila multiobjetivo en variables binarias (MOKP/0-1) es un problema combinatorio bien conocido y ampliamente manejado en la comunidad multi-objetivo. Un considerable número de métodos exactos y metaheurísticos, ver por ejemplo [3], [5], [12], intentan resolver este problema. En [4], se señala que se genera un elevado número de soluciones superpuestas (overlapping solutions) cuando los AEMOs se aplican a problemas combinatorios con muchas variables de decisión y baja dimensionalidad. La aparición de soluciones superpuestas cuando el Problema de la Mochila 0/1 Bi-Objetivo se resuelve con un AEMO, tiene un significativo impacto negativo sobre la diversidad del frente final de soluciones no-dominadas alcanzado.

Se propone un híbrido de NSGA-II, que subdivide el espacio de los objetivos en varias regiones utilizando la solución Nadir

calculada en cada generación del algoritmo. Las distintas subdivisiones utilizan diferentes estrategias de optimización de las funciones objetivo. La idea que subyace es intensificar la diversidad de soluciones del frente alcanzado, permitiendo que soluciones dominadas por los extremos del frente no-dominado alcanzado en cada generación del algoritmo puedan entrar en la población  $N$  no-dominada del algoritmo.

El resto del trabajo se organiza de la siguiente manera. En la sección II se presentan algunos conceptos básicos para entender mejor este trabajo. En la sección III se describe el método propuesto. Los resultados experimentales se detallan en la sección IV. Por último, en la sección V se presentan las conclusiones.

## II. CONCEPTOS BÁSICOS

En términos de minimización, un POM puede ser definido de la siguiente forma:

$$\begin{aligned} \text{Min. } F(x) &= f_1(x), f_2(x), \dots, f_n(x) \\ \text{s.a.} \\ g_k(x) &\leq 0 & k \in (1, 2, \dots, p) \\ h_l(x) &= 0 & l \in (1, 2, \dots, q) \end{aligned} \quad (1)$$

donde  $F(x)$  es el vector de objetivos a minimizar y  $n \geq 2$  el número de objetivos. Las ecuaciones  $g_k(x) \leq 0$  y  $h_l(x) = 0$  representan respectivamente  $p$  restricciones de desigualdad y  $q$  restricciones de igualdad. Los valores de  $x$  que satisfacen el conjunto de las  $(p + q)$  restricciones, definen el espacio realizable  $S$ . El vector  $x = (x_1, x_2, \dots, x_m) \in S$  es un vector solución de  $m$  variables de decisión.

El conjunto de las imágenes de cada solución realizable en el espacio de la decisión, conforma el conjunto de soluciones realizables en el espacio de los objetivos  $Z = f(S)$  definido como  $Z = \{z_1 = f_1(x), \dots, z_n = f_n(x), \forall x \in S\}$  y donde  $z = (z_1, \dots, z_n) \in R^n$  representa una solución realizable en el espacio de los objetivos.

Una solución  $z^t = (z_1^t, z_2^t, \dots, z_n^t) \in Z$  domina una solución  $z^u = (z_1^u, z_2^u, \dots, z_n^u) \in Z$  y se le conoce como Pareto-óptima si se verifican las siguientes condiciones:

1.  $z_j^t \leq z_j^u \quad \forall j \in (1, 2, \dots, n)$
2.  $\exists j \in (1, 2, \dots, n)$  tal que  $z_j^t < z_j^u$

Al conjunto de soluciones Pareto-óptimas en el espacio de soluciones se le llama conjunto óptimo de Pareto y a su imagen en el espacio de objetivos frente óptimo de Pareto.

### II-A. MOEA/D con especificación de Zhang del punto de referencia

Básicamente, MOEA/D trabaja descomponiendo un POM en un número finito de sub-problemas escalares y resolviéndolos simultáneamente mediante la evolución de una población de soluciones. Algunos enfoques para convertir un POM en un sub-problema escalar se pueden consultar en [12]. El enfoque de Tchebycheff se expresa como sigue:

$$\begin{aligned} \text{Min. } g^{te}(x|\lambda, z^*) &= \max_{1 \leq i \leq n} \{\lambda_i f_i(x) - z_i^*\} \\ \text{s.a. } x &\in X \end{aligned} \quad (2)$$

donde  $z^* = (z_1^*, \dots, z_n^*)$  es el punto de referencia (PR) especificado en este trabajo de la siguiente forma:

$$z_i^* = \alpha * \min\{f_i(x) | x \in X\} \text{ paracada } i = 1, \dots, n \quad (3)$$

y donde  $\alpha \geq 1$ .

### II-B. MOEA/D con especificación de Ishibuchi del punto de referencia

Ishibuchi et al. proponen en [6] usar en (2) la siguiente especificación para el PR:

$$z^R = z_i^* - \alpha_t (z_i^{max} - z_i^*) \quad (4)$$

donde  $z_i^* = (z_1^*, \dots, z_n^*)$  corresponde al mínimo valor en la función objetivo  $i$ ,  $z_i^{max} = (z_1^{max}, \dots, z_n^{max})$  corresponde al máximo valor de la función objetivo  $i$  en la generación en curso y  $\alpha_t$  es un parámetro que decrece en cada generación del algoritmo. De (4) es obvio que cuando  $\alpha_t = 0$  los valores  $z^R$  y  $z^*$  tienen los mismos valores.

Para hacer que el valor  $z^R$  se aproxime gradualmente al valor del punto de referencia  $z^*$  durante la ejecución del algoritmo, el valor  $\alpha_t$  es modificado en cada generación según:

$$\alpha_t = \alpha (t_{max} - t) / (t_{max} - 1) \quad (5)$$

donde  $\alpha$  es un valor inicial de  $\alpha_t$ ,  $t_{max}$  es el número máximo de generaciones del algoritmo y  $t$  es la generación actual. Nótese que el valor final de  $\alpha_t$  en la última generación es cero, i.e.,  $z^R$  tiende a  $z^*$  durante la ejecución del algoritmo.

## III. MÉTODO PROPUESTO

El algoritmo propuesto en este trabajo consiste en una versión modificada de NSGA-II, en los siguientes términos:

1. En cada generación  $t$  del algoritmo: una población  $R_t = P_t + Q_t$  es construida con  $P_t$  la población de padres de tamaño  $N$  y  $Q_t$  la población de hijos (tamaño  $N$ ) generados de las operaciones de cruzamiento y mutación a partir de la población  $N$  construida en la generación  $t-1$ .
2. A partir de la población  $R_t$  la solución Nadir es identificada mediante algún método.
3. En base a la solución Nadir el espacio de los objetivos se divide en tres regiones independientes  $R_1$ ,  $R_2$  y  $R_3$  tal como se indica en la Fig. 1 izquierda.
4. Las soluciones de cada región  $R_1$ ,  $R_2$  y  $R_3$  son clasificadas (complejidad computacional  $O(n^2N)$ ) en diferentes frentes no-dominados ( $F_1, F_2, \dots, F_n$ ). Para la clasificación de las soluciones, se usan diferentes criterios de optimización de las funciones objetivo  $f_1$  y  $f_2$ .
  - a) Región  $R_1$ : Las dos funciones objetivo  $f_1$  y  $f_2$  son siempre maximizadas (ver Fig. 1 derecha).
  - b) Región  $R_2$ : La función  $f_1$  es siempre maximizada. La función  $f_2$  es maximizada si se cumple la condición  $t \geq nt$ , en caso contrario  $f_2$  es minimizada (ver Fig. 1 derecha). El valor  $t$  es la generación actual y  $nt$  un parámetro (número de generaciones



que se maximiza o minimiza la función objetivo) que se define como:

$$nt = \alpha t_{max} \quad 0 \leq \alpha \leq 1 \quad (6)$$

- c) Región R3: La función  $f_2$  es siempre maximizada. La función  $f_1$  es maximizada si se cumple la condición  $t \geq nt$ , en caso contrario  $f_1$  es minimizada (ver Fig. 1 derecha).

Finalizado el paso 4, toda la población  $R_t$  queda clasificada en frentes de no-dominación ( $F_1, F_2, \dots, F_n$ ).

5. Para completar la población  $P_{t+1}$  hasta alcanzar un tamaño  $N$ , como en NSGA-II, las soluciones con menor rango primero, y mayor crowding-distance segundo, son escogidas.

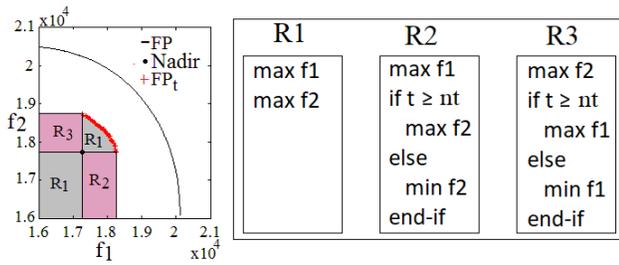


Figura 1. División propuesta del espacio de los objetivos en base a la solución Nadir (izquierda). Criterios de optimización de las funciones objetivo para cada región  $R_1$ ,  $R_2$  y  $R_3$  (derecha).

#### IV. EXPERIMENTOS Y COMPARACIONES

##### IV-A. Problema de la Mochila Multiobjetivo MOKP/0-1

El problema de la mochila multiobjetivo en variables binarias (MOKP/0-1) consiste en una serie de objetos o ítems con un peso, un beneficio asociado a cada uno de ellos y un límite de capacidad para cada mochila. Así, la tarea radica en encontrar el subconjunto de objetos que maximicen los beneficios totales de cada mochila y que puedan ser colocados en dichas mochilas sin exceder sus límites de capacidad. El problema es de complejidad NP-difícil y puede ser usado para modelar cualquier aplicación real que se ajuste al modelo descrito en (7).

El MOKP/0-1 puede ser definido formalmente como sigue:

$$\begin{cases} \max. & f_i(x) = \sum_{j=1}^m b_{ij}x_j \quad i = 1, \dots, n \\ \text{s.a.} & \sum_{j=1}^m w_{ij}x_j \leq c_i \quad x_j \in \{0, 1\} \end{cases} \quad (7)$$

donde:  $m$ =número de objetos,  $x_j$ =variable de decisión,  $n$ =número de sacos,  $b_{ij}$ =beneficio objeto  $j$  según saco  $i$ ,  $w_{ij}$ =peso objeto  $j$  según saco  $i$  y  $c_i$  = capacidad saco  $i$ .

##### IV-B. Configuración de parámetros y métricas

En este trabajo, las implementaciones de NSGA-II y MOEA/D se han realizado según [2] y [12]. Ambos algoritmos son aplicados sobre el 500-MOKP/0-1 con dos objetivos, los

datos del problema y frente óptimo pueden descargarse de: <http://www.tik.ee.ethz.ch/sop/download/supplementary/testProblemSuite/>.

En todos los experimentos se utilizó codificación binaria, cruce uniforme de probabilidad 0.8 y probabilidad de mutación (bit a bit) de 1/500. Un número de 400000 evaluaciones de la función objetivo se usó como condición de parada. Tres tamaños de la población  $N=50$ ,  $N=100$  y  $N=200$  soluciones fueron utilizadas en los tres algoritmos NSGA-II/OSD, NSGA-II y MOEA/D. Los valores examinados para el parámetro  $\alpha$  definido en (6) de balance convergencia/diversidad de NSGA-II/OSD fueron  $\alpha=0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9$  y 1.0. Con MOEA/D, los valores ensayados de  $\alpha$  en el cálculo del punto de referencia  $z^*$  según la especificación de Zhang definida en (3) fueron  $\alpha=1.0, 1.05, 1.1, 1.15, 1.2, 1.25, 1.3$ ; en la versión de Ishibuchi para el cálculo del punto de referencia  $z^R$  definido en (4) y (5), los valores se fijaron en  $\alpha=0.0, 0.05, 0.1, 0.5, 1.0, 1.1, 2.0, 3.0, 4.0, 5.0$  y 10.0.

Para la comparación de los resultados obtenidos por los algoritmos, se emplearon la S-metric o hipervolumen  $H$  (punto de referencia usado el 0,0) sugerida en [13] y visualizaciones de los frentes de soluciones de Pareto alcanzados de valor  $H$  más próximo al valor medio final calculado en 30 ejecuciones independientes.

##### IV-C. Análisis previo: NSGA-II/OSD y efectos de variar el parámetro $\alpha$

En esta subsección se analizan las influencias en la convergencia y diversidad del frente de soluciones alcanzado, cuando se varía el parámetro  $\alpha$  en la ecuación (6) en el algoritmo propuesto NSGA-II/OSD. En la Fig. 2 (izquierda), se muestran los valores del hipervolumen medio al modificar los valores del parámetro  $\alpha$ . Se puede observar que los mejores valores de  $H$  se obtienen para valores intermedios del parámetro  $\alpha$ . Para mejor interpretar estos resultados, la Fig. 2 (centro) muestra los efectos sobre la distribución de soluciones de los frentes de Pareto obtenidos cuando  $N=200$ . Los frentes de Pareto de menor diversidad (mayor convergencia) y mayor diversidad (menor convergencia) se obtienen cuando  $\alpha=0.0$  y  $\alpha=1.0$  respectivamente. El frente con el mejor valor del hipervolumen se alcanza cuando  $\alpha=0.5$ , ver la Fig. 2 (derecha).

##### IV-D. Resultados comparativos: NSGA-II/OSD vs NSGA-II

En esta subsección se compara el algoritmo NSGA-II/OSD propuesto en este trabajo con el algoritmo NSGA-II de Deb et al. [2]. La Fig. 3 muestra los frentes de soluciones de Pareto obtenidos por ambos algoritmos. Se observa que el frente de soluciones alcanzado con el método propuesto ( $\alpha=0.5$ ) tiene bastante más diversidad que el alcanzado por NSGA-II, aunque en términos de convergencia parece que NSGA-II obtiene mejor valor. La Fig. 4 (izquierda) muestra que en términos de la métrica  $H$ , el frente de soluciones logrado por NSGA-II/OSD es mejor que el obtenido por NSGA-II; también la Fig. 4 (derecha) señala para NSGA-II/OSD un menor valor de la desviación estándar del hipervolumen. En la Fig. 5 (izquierda) se aprecia que durante la evolución de

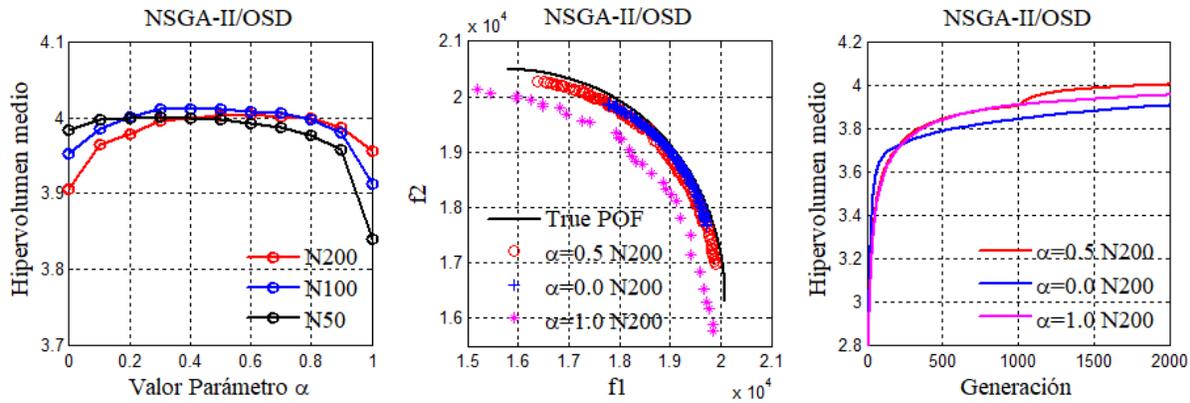


Figura 2. Valores H al variar el parámetro  $\alpha$  en el algoritmo propuesto NSGA-II/OSD (izquierda). Gráficas de soluciones no-dominadas con el valor H más próximo al valor medio final en 30 ejecuciones (centro). Evolución del hipervolumen medio de los frentes mostrados en la gráfica central (derecha).

los algoritmos, el porcentaje de soluciones diferentes en la población N de soluciones es siempre mejor para el algoritmo propuesto, lo que justifica la mayor diversidad del frente de soluciones logrado por NSGA-II/OSD. También, el número de reparaciones por ensayo realizadas a los cromosomas de las soluciones de la población para que sean factibles, es menor con el método propuesto tal como se aprecia en la Fig. 5 (derecha).

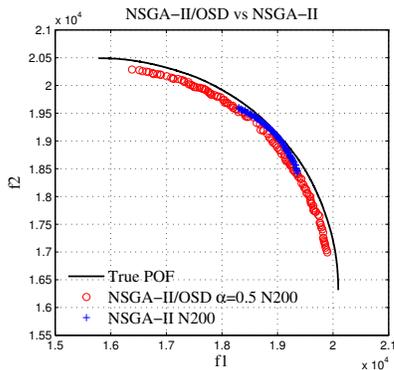


Figura 3. NSGA-II/OSD versus NSGA-II: gráficas de soluciones no-dominadas con el valor H más próximo al valor medio final en 30 ejecuciones.

#### IV-E. Análisis previo: MOEA/D e importancia de la especificación del punto de referencia PR

Dos especificaciones del punto de referencia -la de Zhang y la de Ishibuchi descritas en los apartados II-A y II-B- se comparan en esta subsección. La Fig. 6 (izquierda) muestra los valores del hipervolumen medio H al variar el valor  $\alpha$  en la especificación de Zhang del punto de referencia en MOEA/D según la ecuación (3). El valor H crece hasta un valor máximo (cuando  $\alpha = 1.2$ ) para luego volver a decrecer. También se pueden observar, en la Fig. 7 (izquierda), los efectos sobre la diversidad de los frentes de soluciones alcanzados cuando  $\alpha=1.0$  (mínima diversidad) y  $\alpha=1.2$  (máxima diversidad y máximo valor de H).

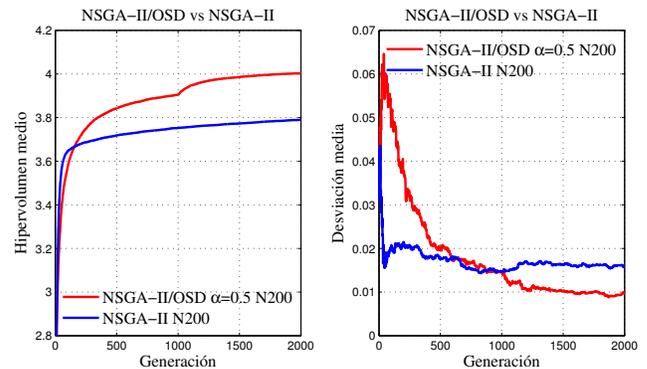


Figura 4. NSGA-II/OSD versus NSGA-II: Evolución de los valores de los hipervolumenes medio (izquierda) y desviaciones del hipervolumen (derecha).

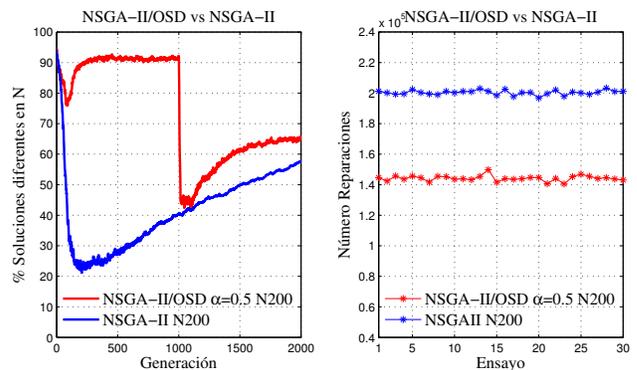


Figura 5. NSGA-II/OSD versus NSGA-II: Evolución de los porcentajes medios de soluciones diferentes en las poblaciones N (izquierda) y de los números de reparaciones de los cromosomas por ensayo (derecha).

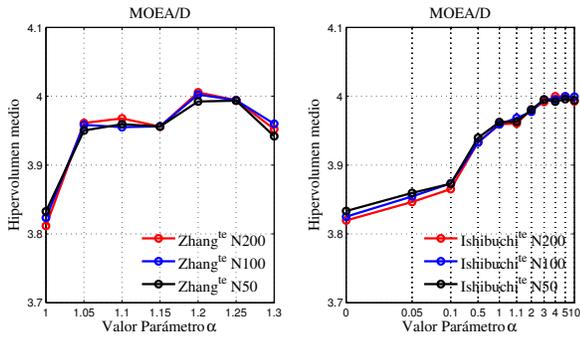


Figura 6. Valores H al variar el parámetro  $\alpha$  en la especificación de Zhang del PR en MOEA/D (izquierda). Valores H al variar el parámetro  $\alpha$  en la especificación de Ishibuchi del PR en MOEA/D (derecha).

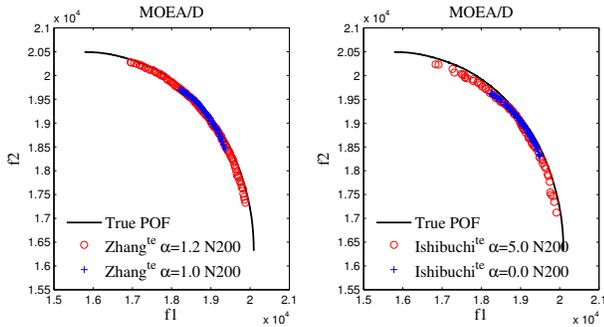


Figura 7. Gráficas de soluciones no-dominadas con el valor H más próximo al valor medio final en 30 ejecuciones: especificación de Zhang del PR (izquierda), especificación de Ishibuchi del PR (derecha).

Utilizando ahora en MOEA/D la especificación de Ishibuchi del punto de referencia según las ecuaciones (4) y (5), también al variar el valor  $\alpha$  se obtienen diferentes valores del hipervolumen H. La Fig. 6 (derecha) señala que el valor H crece hasta un valor máximo (cuando  $\alpha \geq 3$ ) a partir del cual permanece estable.

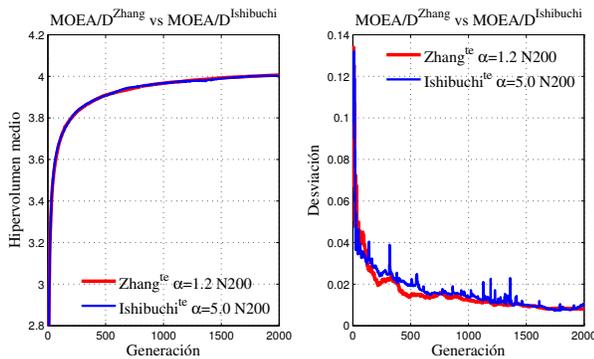


Figura 8. Evolución de los hipervolumenes medio (izquierda) y desviaciones del hipervolumen (derecha) usando las especificaciones de Zhang e Ishibuchi del PR en MOEA/D.

Una comparación de MOEA/D usando las especificaciones de Zhang con el valor  $\alpha=1.2$  e Ishibuchi con valores  $\alpha \geq 3$ , muestra valores parecidos de la métrica H (Fig. 8 izquierda)

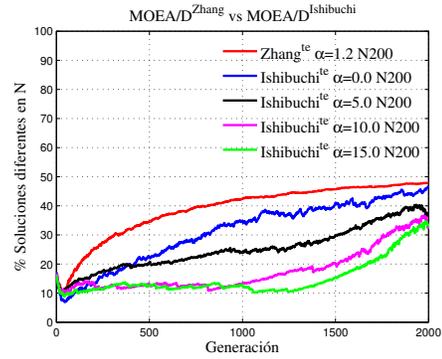


Figura 9. Evolución de los porcentajes medios de soluciones diferentes en las poblaciones N.

y de la desviación de H (Fig. 8 derecha) a lo largo de la evolución del algoritmo. No obstante, hay que señalar que el frente de soluciones logrado por MOEA/D con la especificación de Ishibuchi es más pobre (ver Fig. 7 derecha) en número de soluciones diferentes en la población N que el logrado usando la especificación de Zhang. En la Fig. 9 se muestra que utilizando la especificación de Zhang, MOEA/D consigue siempre en toda la evolución del algoritmo un mayor número de soluciones diferentes en la población N; por otro lado, en dicha gráfica también se observa que incrementando el valor  $\alpha$  usando la especificación de Ishibuchi en MOEA/D, hay un decremento del número de soluciones diferentes en N.

IV-F. Resultados comparativos: NSGA-II/OSD vs MOEA/D

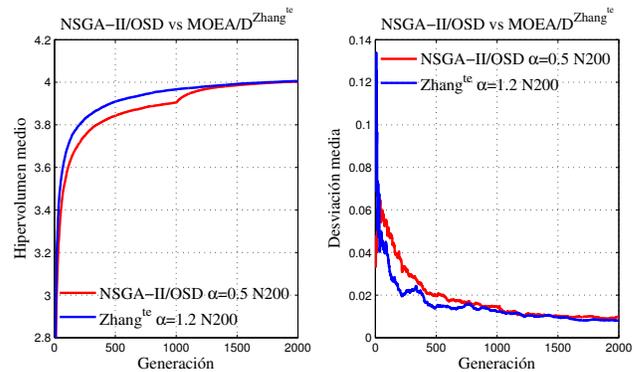


Figura 10. NSGA-II/OSD versus MOEA/D: Evolución de los valores de los hipervolumenes medio (izquierda) y desviaciones del hipervolumen (derecha).

En esta subsección comparamos el algoritmo NSGA-II/OSD propuesto en este trabajo y el algoritmo MOEA/D con especificación de Zhang del PR, utilizando en ambos algoritmos aquel valor  $\alpha$  que proporcionó el mejor valor del hipervolumen medio H tras 30 ejecuciones independientes y que según los experimentos descritos en anteriores apartados fue  $\alpha=1.2$  para ambos algoritmos. En la Fig. 10 (izquierda) se observa que durante la primera mitad de la evolución de los algoritmos, MOEA/D tiene un mejor valor de H luego, los valores H obtenidos por ambos algoritmos se igualan justo a partir de

que las estrategias usadas con NSGA-II/OSD en las regiones R2 y R3 (Fig. 1) son a maximizar ambos objetivos. Idéntica conclusión se obtiene con las desviaciones del hipervolumen en la Fig. 10 (derecha).

De otra parte, en la Fig. 11 se observa que el frente de soluciones alcanzado con el método propuesto obtiene más diversidad que el alcanzado por MOEA/D con especificación de Zhang del PR, aunque en términos de convergencia es MOEA/D quien parece tener mejor valor. Estas diferencias se pueden explicar porque NSGA-II/OSD presenta siempre un mejor porcentaje de soluciones diferentes en la población N durante la evolución del algoritmo tal como se ve en la Fig. 12 (izquierda). Finalmente, la Fig. 12 (derecha) muestra que NSGA-II/OSD realiza un menor número de reparaciones de cromosomas para factibilizar las soluciones.

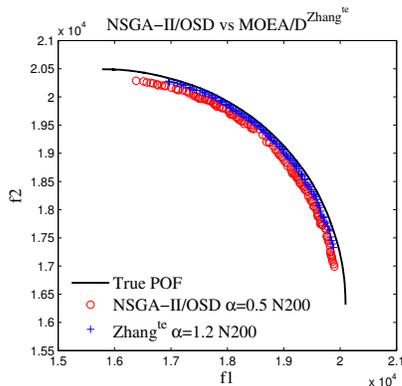


Figura 11. NSGA-II/OSD versus MOEA/D: gráficas de soluciones no-dominadas con el valor H más próximo al valor medio final en 30 ejecuciones.

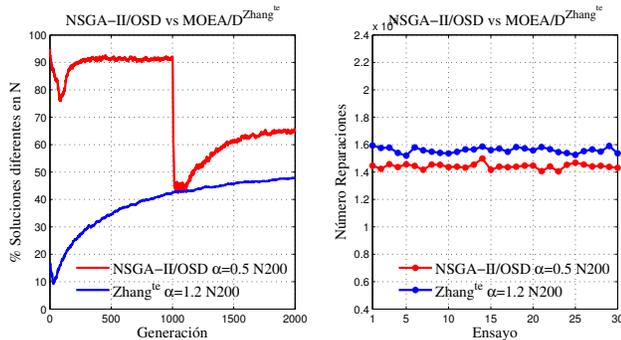


Figura 12. NSGA-II/OSD versus MOEA/D: Evolución de los porcentajes medios de soluciones diferentes en las poblaciones N (izquierda) y de los números de reparaciones de los cromosomas por ensayo (derecha).

## V. CONCLUSIONES

En este trabajo se propone un algoritmo evolutivo multi-objetivo (NSGA-II/OSD) que hibridiza NSGA-II. El algoritmo subdivide el espacio de los objetivos en varias regiones utilizando la solución Nadir calculada en cada generación del algoritmo. Las distintas subdivisiones utilizan diferentes estrategias de optimización de las funciones objetivo. El algoritmo NSGA-II/OSD propuesto permite definir un parámetro

$\alpha \in [0, 1]$  muy fácil de usar, que permite balancear la diversidad/convergencia del frente de soluciones no-dominadas alcanzado por el algoritmo; para el valor  $\alpha=1.2$  el algoritmo logra su mejor valor de hipervolumen medio.

El algoritmo propuesto obtiene muy buen desempeño y mejores resultados cuando es comparado con NSGA-II. Cuando NSGA-II/OSD es comparado con MOEA/D con la especificación del punto de referencia de Zhang según (3), en términos de la métrica del hipervolumen medio, ambos algoritmos obtienen valores similares. No obstante, NSGA-II/OSD logra una mayor diversificación de soluciones en el frente no-dominado final alcanzado, mientras MOEA/D parece alcanzar mejor convergencia.

## AGRADECIMIENTOS

Agradecemos el soporte económico del Departamento de Informática y Sistemas de la Universidad de Las Palmas de Gran Canaria.

## REFERENCIAS

- [1] Carlos A. Coello Coello, Gary B. Lamont, David A. Van Veldhuizen. Evolutionary algorithms for solving multi-objective problems. Springer-Verlag Berlin, Heidelberg, 2006.
- [2] K. Deb, A. Pratap, S. Agrawal, T. Meyarivan. A Fast and Elitist Multiobjective Genetic Algorithm : NSGA-II. IEEE Transactions on Evolutionary Computation, Vol. 6, n2, pages 182-197, 2002.
- [3] X. Gandibleux, A. Freville. Tabu search based procedure for solving the 0-1 multiobjective knapsack problem: the two objectives case. J. of Heuristics, 6(3): 361-383, 2000.
- [4] Hisao Ishibuchi, Kaname Narukawa, Yusuke Nojima. Handling of Overlapping Objective Vectors in Evolutionary Multiobjective Optimization. International Journal of Computational Intelligence Research 1(2005): 1-18, 2005
- [5] Hisao Ishibuchi, Naoya Akedo, Yusuke Nojima. Behavior of multiobjective evolutionary algorithms on many-objective knapsack problems. IEEE Transactions on Evolutionary Computation 19(2), 2015.
- [6] Hisao Ishibuchi, Ken Doi, Yusuke Nojima. Reference Point Specification in MOEA/D for Multi-Objective and Many-Objective Problems. 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2016.
- [7] R. Saborido, A.B. Ruiz, M. Luque. Global WASF-GA: An Evolutionary Algorithm in Multiobjective Optimization to approximate the whole Pareto Optimal Front. Evolutionary Computation 25(2): 309-349, 2017.
- [8] Mingzhao Wang, Yuping Wang, Xiaoli Wang. A Space Division Multiobjective Evolutionary Algorithm Based on Adaptive Multiple Fitness Functions. International Journal of Pattern Recognition and Artificial Intelligence 30(3), 2016.
- [9] Rui Wang, Jian Xiong, Hisao Ishibuchi, Guohua Wu, Tao Zhang. On the effect of reference point in MOEA/D for multi-objective optimization. Applied Soft Computing 58(2017): 25-34, 2017.
- [10] Yuping Wang, Chuangyin Dang. Improving Multiobjective Evolutionary Algorithm by Adaptive Fitness and Space Division. In: Wang L., Chen K., Ong Y.S. (eds) Advances in Natural Computation. ICNC 2005. LNCS, vol 3612. Springer, Berlin, Heidelberg, 2005.
- [11] Zhenkun Wang, Qingfu Zhang, Hui Li, Hisao Ishibuchi, Licheng Jiao. On the use of two reference points in decomposition based multiobjective evolutionary algorithms. Swarm and Evolutionary Computation 34(2017): 89-102, 2017.
- [12] Q. Zhang and H. Li. MOEA/D: A multi-objective evolutionary algorithm based on decomposition. IEEE Trans. Evol. Comput., 11(6): 712-731, 2007.
- [13] E. Zitzler, L. Thiele, *Multiobjective optimization using evolutionary algorithms - A comparative case study*, In A.E. Eiben et al. (Eds.): Parallel Problem Solving from Nature, LNCS, Volume 1498, pages 292-301, Springer, Heidelberg, 1998.



# Algoritmo Evolutivo Multi-Objetivo para la Toma de Decisiones Interactiva en Optimización Dinámica

Cristóbal Barba-González

*Lenguajes y Ciencias de la Computación*  
Universidad de Málaga  
Málaga, España  
cbarba@lcc.uma.es

José M. García-Nieto

*Lenguajes y Ciencias de la Computación*  
Universidad de Málaga  
Málaga, España  
jnieto@lcc.uma.es

Ana B. Ruiz

*Economía Aplicada (Matemáticas)*  
Universidad de Málaga  
Málaga, España  
abruiz@uma.es

Antonio J. Nebro

*Lenguajes y Ciencias de la Computación*  
Universidad de Málaga  
Málaga, España  
antonio@lcc.uma.es

Mariano Luque

*Economía Aplicada (Matemáticas)*  
Universidad de Málaga  
Málaga, España  
mluque@uma.es

José F. Aldana-Montes

*Lenguajes y Ciencias de la Computación*  
Universidad de Málaga  
Málaga, España  
jfam@lcc.uma.es

**Resumen**—Debido al creciente interés en el análisis de datos en streaming en entornos Big Data para la toma de decisiones, cada vez es más común la aparición de problemas de optimización dinámica que involucran dos o más objetivos en conflicto. Sin embargo, los enfoques que combinan optimización dinámica multi-objetivo con la articulación de preferencias para la toma de decisiones son todavía escasos. En este artículo, proponemos un nuevo algoritmo de optimización dinámica multi-objetivo llamado InDM2, que permite incorporar preferencias del experto (humano) de cara a la toma de decisiones para guiar el proceso de búsqueda. Con InDM2, el decisor no solo puede expresar sus preferencias mediante uno o más puntos de referencia (que definen la región de interés deseada), sino que estos puntos también se pueden modificar de manera interactiva. La propuesta incorpora métodos para mostrar gráficamente las diferentes aproximaciones de la región de interés obtenidas durante el proceso de optimización. El decisor puede así inspeccionar y cambiar, en tiempo de optimización, la región de interés de acuerdo con la información mostrada. Las principales características de InDM2 son descritas y se analiza su funcionamiento mediante casos de uso académicos.

**Index Terms**—Optimización Multi-Objetivo Dinámica, Toma de Decisiones, Selección de Preferencias, Algoritmos Interactivos

## I. INTRODUCCIÓN

En la actualidad, aunque la mayoría de los esfuerzos se centran en abordar problemas de optimización multi-objetivo (MOP) estáticos, existe un creciente interés en aquellos escenarios en los que el problema cambia de alguna manera con el tiempo, es decir, MOP dinámicos o DMOPs [1].

Recientemente, han ido apareciendo varias propuestas de metaheurísticas para la resolución de DMOPs [2]–[5]. Al tratar con un DMOP, siempre que existan cambios en el entorno que afecten a las soluciones del problema (es decir, en la población o en el conjunto de soluciones en el frente de Pareto), el algoritmo de optimización debe reaccionar para adaptar la búsqueda a las nuevas características del problema [6]. Esto significa que las metaheurísticas de optimización dinámica

multi-objetivo deben poder detectar cuándo cambia el problema y aplicar una estrategia para adaptarse a los cambios.

Sin embargo, analizar soluciones preferidas en el frente de Pareto aproximado y compararlas al mismo tiempo puede ser una tarea difícil en el proceso de toma de decisiones, especialmente en presencia de muchos objetivos. De hecho, puede ser computacionalmente costoso generar una gran cantidad de soluciones que aproximen todo el frente de Pareto, particularmente cuando se tratan problemas reales de la industria. Incluso, puede suponer un esfuerzo innecesario si el decisor está únicamente interesado en un subconjunto de soluciones ubicadas en un región particular.

Una forma de aliviar estos problemas es incorporar información sobre las preferencias del decisor en la metaheurística multi-objetivo, para enfocar progresivamente el proceso de búsqueda sobre aquel subconjunto de soluciones que corresponden a estas preferencias, conocido como la *región de interés*. Por lo tanto, en lugar de aproximar todo el frente de Pareto, la idea es aproximar sólo la región de interés.

Mientras que el manejo de preferencias ha sido ampliamente estudiado en su aplicación para MOPs estáticos en el campo de la toma de decisiones multi-criterio (*Multiple Criteria Decision Making - MCDM*) [7]–[9], apenas se ha explorado en la optimización dinámica de múltiples objetivos. En ese sentido, en un contexto donde el frente de Pareto puede cambiar con el tiempo, la especificación de preferencias que determinan la región de interés puede ser difícil debido al hecho de que el problema en sí cambia constantemente. Por lo tanto, una metaheurística de optimización dinámica multi-objetivo que incorpore preferencias, debería prestar atención especial a estas dos características simultáneamente: (1) visualización, para proporcionar al decisor una imagen gráfica de las aproximaciones de la región o regiones de interés de los frentes de Pareto que se encuentran durante el proceso de optimización; y (2) interactividad, para permitir que el decisor pueda indicar nueva información si quiere redefinir sus preferencias (es decir,

indicar una nueva región de interés) en base a su experiencia previa y al conocimiento que progresivamente adquiere sobre el problema al interactuar con el proceso de optimización.

Con esta motivación, proponemos en este artículo InDM2 (*Interactive Dynamic Multi-Objective Decision Making*), una nueva propuesta algorítmica que cumple con estos requisitos. InDM2 está diseñado para actuar como framework algorítmico bajo el que se puede incorporar cualquier metaheurística de optimización multi-objetivo basada en puntos de referencia, para la articulación de preferencias, delegando así en él el proceso de resolución del DMOP. Un punto de referencia está formado por valores de aspiración que el decisor desea alcanzar para cada una de las funciones objetivo.

En particular, hemos considerado una versión dinámica de dos algoritmos evolutivos basados en puntos de referencia: WASF-GA [10] y R-NSGA-II [11]. El propósito de WASF-GA es aproximar la región de interés determinada por el punto de referencia mediante el uso de una función escalarizada de logro [12] y un conjunto de vectores de pesos. Para ello, se clasifican los individuos en fronteras en base a los valores que alcanzan para dicha función. El algoritmo R-NSGA-II considera como información preferencial uno o varios puntos de referencia y modifica la distancia crowding y el operador niching de NSGA-II [13] para enfatizar las soluciones cercanas al/los punto(s) de referencia dado(s) por el decisor.

InDM2 incorpora un mecanismo que permite al decisor (si así lo desea) actualizar interactivamente el punto de referencia al resolver un DMOP. Además, ofrece un mecanismo para visualizar “sobre la marcha” las aproximaciones de la región de interés que se generan a lo largo del proceso de solución. Además, InDM2 se ha implementado con jMetalSP [14], por lo que todas las características de esta librería algorítmica están incorporadas en la propuesta, incluida la posibilidad de utilizar tecnologías Big Data, como Apache Spark. Esto permite, por ejemplo, procesar en streaming los datos almacenados en HDFS (el sistema de archivos Hadoop [15]), además de usar toda la potencia de los clústeres Spark.

Así, las principales contribuciones de este artículo son:

- Se presenta InDM2, un novedoso algoritmo que combina optimización dinámica multi-objetivo, toma de decisiones multi-criterio e interactividad. Una característica clave en InDM2 es el mecanismo para visualizar, en tiempo de optimización, las aproximaciones de la región de interés que se generan, junto con la posibilidad de indicar puntos de referencia para guiar estas aproximaciones.
- La propuesta se ha implementado dentro del framework jMetalSP, por lo que se puede utilizar para optimización en contextos Big Data, aprovechando las características del procesamiento de datos en streaming distribuido de Apache Spark. Esta implementación está disponible como código abierto en repositorio GitHub de jMetalSP<sup>1</sup>.
- Se presentan dos casos de estudio para ilustrar el funcionamiento de InDM2 en la resolución de problemas dinámicos del benchmark FDA para DMOPs [6]. En con-

creto, se utilizan las metaheurísticas interactivas WASF-GA y R-NSGA-II como optimizador base para los dos ejemplos sobre el problema FDA2.

El resto del artículo se organiza de la siguiente forma. La Sección II está dedicada a describir conceptos previos necesarios para la explicación de la propuesta. En la Sección III, se describen la estructura y los principales componentes de InDM2. La Sección IV explica los experimentos realizados a modo de caso de uso. Finalmente, la Sección V recoge las principales conclusiones y trabajo futuro.

## II. CONCEPTOS PREVIOS

Una forma común de expresar preferencias consiste en indicar valores deseables para las funciones objetivo, que constituyen las componentes de lo que se conoce como punto de referencia. Este concepto se introdujo en [12] para MOP estáticos, aunque se puede adaptar fácilmente a DMOP.

Para un DMOP con  $k$  funciones objetivo, en un instante de tiempo  $t$ , un *punto de referencia* viene dado por  $\mathbf{q}_t = (q_{t,1}, \dots, q_{t,k})^T$ , donde  $q_{t,i}$  es un nivel de aspiración para la función objetivo  $f_i(\cdot, t)$  proporcionada por el decisor ( $i = 1, \dots, k$ ). Por lo general, se dice que  $\mathbf{q}_t$  es *alcanzable* si existe, al menos, una solución factible del problema  $t$  cuyo vector objetivo iguala o domina  $\mathbf{q}_t$ . De lo contrario, se dice que el punto de referencia es *inalcanzable*, es decir, no todos los niveles de aspiración se pueden alcanzar o dominar simultáneamente.

Para un punto de referencia  $\mathbf{q}_t$ , se puede minimizar la *función escalarizada de logro* propuesta en [12] sobre el conjunto factible, para encontrar la solución óptima de Pareto que mejor satisfaga las expectativas del decisor en el instante  $t$ . Dado un vector de pesos en el instante  $t$ ,  $\mu_t = (\mu_{t,1}, \dots, \mu_{t,k})^T$  con  $\mu_{t,i} > 0$  ( $i = 1, \dots, k$ ), y un valor real pequeño  $\rho \geq 0$ , la función de logro propuesta en [12] viene dada por:

$$s(\mathbf{q}_t, \mathbf{f}(\mathbf{x}, t), \mu_t) = \max_{i=1, \dots, k} \{ \mu_{t,i} (f_i(\mathbf{x}, t) - q_{t,i}) \} + \rho \sum_{i=1}^k \mu_{t,i} (f_i(\mathbf{x}, t) - q_{t,i}).$$

## III. PROPUESTA ALGORÍTMICA: INDM2

El componente principal de InDM2 es una metaheurística multi-objetivo dinámica basada en preferencias, que actúa como motor de optimización. Una descripción más detallada de la implementación se puede encontrar en [16]. Para este trabajo, se han implementado nuevas versiones dinámicas de los algoritmos WASF-GA y R-NSGA-II de la siguiente manera.

La arquitectura orientada a objetos de jMetalSP permite reutilizar la plantilla de algoritmos evolutivos proporcionada por jMetal<sup>2</sup>. Esta plantilla tiene un método `run()` que codifica el pseudo-código de un algoritmo evolutivo genérico. Las implementaciones de las versiones dinámicas de WASF-GA y R-NSGA-II siguen esta plantilla, por lo

<sup>1</sup><https://github.com/jMetal/jMetalSP>

<sup>2</sup><https://jmetal.github.io/jMetal/>



que el desarrollo de InDM2 sobre WASF-GA y R-NSGA-II requiere simplemente la redefinición de dos métodos. En primer lugar, se debe adaptar el comportamiento del método `isStoppingConditionReached()`, ya que en lugar de simplemente terminar el algoritmo, este método debe hacer que la aproximación de la región de interés esté disponible para los métodos consumidores de datos de InDM2. De esta forma, el algoritmo de optimización subyacente (basado en WASF-GA o R-NSGA-II) pueda comenzar de nuevo teniendo en cuenta esta información. En segundo lugar, al final de cada iteración, el método `updateProgress()` incrementa un contador de evaluación.

Para permitir que el decisor pueda actualizar el(los) punto(s) de referencia “sobre la marcha”, InDM2 lee el(los) nuevo(s) punto(s) de referencia desde teclado (aunque podrían usarse otros métodos más sofisticados). Este evento se detecta mediante el método `updateProgress()`. Para ayudar al decisor a dar un nuevo punto de referencia de acuerdo con sus preferencias y teniendo en cuenta los resultados obtenidos, se ha incluido un consumidor de datos gráfico. Por lo tanto, las aproximaciones de la región de interés generadas por InDM2 se muestran cuando se producen, por lo que el decisor puede visualizarlas y cambiar los puntos de referencia como desee.

Por defecto, InDM2 siempre está funcionando. Esto significa que, si el DMOP no cambia durante un período de tiempo, el algoritmo lo resolverá una y otra vez, utilizando exactamente la misma configuración del problema. Como consecuencia, si el algoritmo converge la mayoría de las veces, la misma aproximación de la región de interés (o una muy similar, dado que estamos usando enfoques estocásticos) se mostrará constantemente. Esto puede ser confuso para el decisor, ya no percibirá cambios evidentes por un período de tiempo. Para evitar esta situación, el consumidor de datos gráficos solo muestra una nueva aproximación en caso de que ésta haya cambiado significativamente, en comparación con la anterior mostrada. Para verificar esto, se calcula internamente el indicador distancia generacional invertida ( $I_{IGD}$ ) [17] desde la aproximación de la región de interés actual, hasta la anterior. La nueva aproximación se mostrará únicamente si el valor de este indicador es inferior a un umbral  $\tau$ .

Todos los DMOP disponibles en jMetalSP tienen un método para averiguar si el problema ha cambiado o no. Por lo tanto, InDM2 solo tiene que llamar a este método al final de cada iteración (es decir, en el método `updateProgress()`), para saber si el parámetro del problema ha cambiado.

Una vez que se ha detectado un cambio en el problema y/o punto(s) de referencia, un aspecto clave en InDM2 es la estrategia de reinicio. Hemos adoptado un enfoque flexible que consiste en definir el reinicio de acuerdo con otras dos subestrategias: una para eliminar soluciones de la población y otra para llenar la población con nuevas soluciones. Para llenar la población, dado un valor  $N' > 0$ , la estrategia seguida es crear al azar  $N'$  nuevas soluciones. Para eliminar las soluciones, se pueden configurar las siguientes estrategias:

- Eliminar las primeras  $N'$  soluciones.
- Eliminar  $N'$  soluciones aleatorias.

- Eliminar las peores  $N'$  soluciones de acuerdo a la distancia crowding.
- Eliminar las peores  $N'$  soluciones de acuerdo a su contribución en hypervolumen con respecto a la última aproximación de la región de interés.

El pseudo-código del InDM2 se muestra en el Algoritmo 1. Después de la fase de inicialización (líneas 1-14), el algoritmo inicia el ciclo infinito (línea 15) que lleva a cabo múltiples rondas consecutivas de optimización dinámica y consumo de datos resultado (visualización). Cada ronda de optimización (líneas 16-25) implica un número máximo de iteraciones ( $G_{max}$ ) en las que se ejecuta el algoritmo evolutivo basado en preferencias (es decir, WASF-GA o R-NSGA-II, línea 17), y se invocan los procedimientos de reinicio cada vez que se detecta un cambio en el punto de referencia (línea 18) o en el estado del problema (línea 20). Al final de cada iteración, la aproximación de la región de interés encontrada se envía a los consumidores de datos (línea 25) y el ciclo comienza de nuevo.

---

#### Algorithm 1 Pseudo-código InDM2

---

```

1:  $N$  ; // Tamaño de población
2:  $N'$  ; // Número de soluciones a reemplazar
3:  $G_{max}$  ; // Número máximo de generaciones
4:  $c, m$  ; // Operadores genéticos (cruce y mutación)
5:  $t \leftarrow 0$  ; // Contador de generación
6:  $A_t$  ; // Estado del problema de optimización
7:  $\mathbf{q}_t$  ; // Punto(s) de referencia inicial(es)
8:  $P$  ; // Algoritmo de optimización basado en preferencias
9:  $\varphi_q$  ; // Estrategia de reinicio ante cambios del punto de referencia
10:  $\varphi_p$  ; // Estrategia de reinicio ante cambios del problema
11:  $M \leftarrow \{\text{WASF-GA, R-NSGA-II}\}$  ; // Optimizadores base
12:  $P_t \leftarrow \text{initializePopulation}(N)$  ;
13:  $\text{evaluate}(P_t, A_t)$  ;
14:  $E_t \leftarrow \text{initializeParetoSet}(P_t)$  ;
15: while true do
16:   while  $t < G_{max}$  do
17:      $(P_{t+1}, E_{t+1}) \leftarrow \text{compute}(M, \mathbf{q}_t, c, m, P_t, A_t)$  ;
18:     if  $\mathbf{q}_{t+1} \neq \mathbf{q}_t$  then
19:        $P'_{t+1} \leftarrow \text{restart}(P_{t+1}, \varphi_q, \mathbf{q}_{t+1}, N')$  ;
20:     else if  $A_{t+1} \neq A_t$  then
21:        $P'_{t+1} \leftarrow \text{restart}(P_{t+1}, \varphi_p, A_{t+1}, N')$  ;
22:     end if
23:      $t \leftarrow t + 1$  ;
24:   end while
25:    $C : (E_{t+1}, \tau)$  ; // Notifica aproximación a consumidores
26:    $t \leftarrow 0$  ;
27: end while

```

---

#### IV. EXPERIMENTOS

El objetivo de este estudio no es tanto la realización de comparativas exhaustivas de rendimiento algorítmico, sino el de ilustrar cómo funciona InDM2 en la práctica, cuando interactúa con un decisor, para así mostrar los beneficios potenciales de la propuesta desde el punto de vista de la toma de decisiones.

En este sentido, se ha probado InDM2 con el problema FD2, introduciendo manualmente las preferencias (es decir, los puntos de referencia) durante el tiempo de ejecución. La

Tabla I: Configuración de InDM2.

Parámetros	
Tamaño de población	50
Probabilidad de cruce	0.9
Probabilidad de mutación	$1/L$ ( $L =$ número de variables)
Número máximo de evaluaciones	25,000
Reinicio por punto de referencia	Eliminar 100 % de las soluciones Generar 100 % de soluciones aleatoriamente
Reinicio por cambio de problema	Eliminar 50 % de soluciones (hipervolumen) Generar 50 % de soluciones aleatoriamente
Consumidores de datos	
Visualizador gráfico	Muestra frentes y puntos de referencia
Front writer	Carga los frentes generados en ficheros
Streaming runtime	
Mecanismo	Java threads

idea es observar cómo InDM2 puede adaptar el proceso de optimización a los cambios (tanto en la configuración del problema como en las preferencias), mostrando así el efecto de estos cambios en las aproximaciones de los frentes de Pareto obtenidas. Nos referimos a las dos configuraciones de InDM2 para los optimizadores base WASF-GA y R-NSGA-II como InDM2<sub>W</sub> y InDM2<sub>R</sub>, respectivamente.

El problema FD2 es un DMOPs de representación continua perteneciente al benchmark FDA [6]. Cada problema de esta familia tiene dependencia con el tiempo  $t$ , que se define mediante la ecuación  $t = \frac{1}{n_t} \lfloor \frac{\sigma}{\sigma_T} \rfloor$ , en la que  $\sigma$  es un contador de generaciones,  $\sigma_T$  es el número de generaciones en las que  $t$  permanece fijo y  $n_t$  es la cantidad de pasos distintos en  $t$ . Para un número real  $a$ ,  $\lfloor a \rfloor$  denota el entero más grande no mayor a  $a$ . En [6], los autores recomiendan establecer  $\sigma_T = 5$  y  $n_t = 10$ .

La formulación de FDA2 se puede encontrar en [6], por lo que siguiendo lo recomendado en este trabajo, se han utilizado soluciones de 31 variables con  $x_I = x_1$ ,  $|x_{II}| = |x_{III}| = 15$ . Este problema se ha seleccionado debido a que las aproximaciones de frentes de Pareto y sus conjuntos de Pareto cambian en el tiempo (tipo II [6]). Por lo tanto, los cambios dinámicos en las aproximaciones causadas por cambios en el punto de referencia se pueden visualizar fácilmente.

La Tabla I muestra la configuración de parámetros utilizada para InDM2. La condición de parada utilizada para informar de los resultados a los procesos consumidores es alcanzar un máximo de 25,000 evaluaciones. Los operadores de variación son SBX como operador de cruce y el de mutación polinómica. El operador de selección es torneo binario. Para la estrategia de reinicio al detectar un cambio en el problema, en primer lugar, se elimina el 50 % de las soluciones de acuerdo con la contribución de hipervolumen; en segundo lugar, se llena la población con nuevas soluciones creadas aleatoriamente. La estrategia de reinicio cuando se proporciona un nuevo punto de referencia es similar, pero en este caso se eliminan todas las soluciones de la población (100 %).

Para generar los eventos temporales que conducirán a cambios en el problema FDA2, hemos utilizado una fuente simple de transmisión de datos que cuenta cada segundo, lo que implica que, con un valor predeterminado de  $\sigma_T$ , el problema se actualiza con una frecuencia de 5 segundos. Además, hemos utilizado dos consumidores de datos, uno para

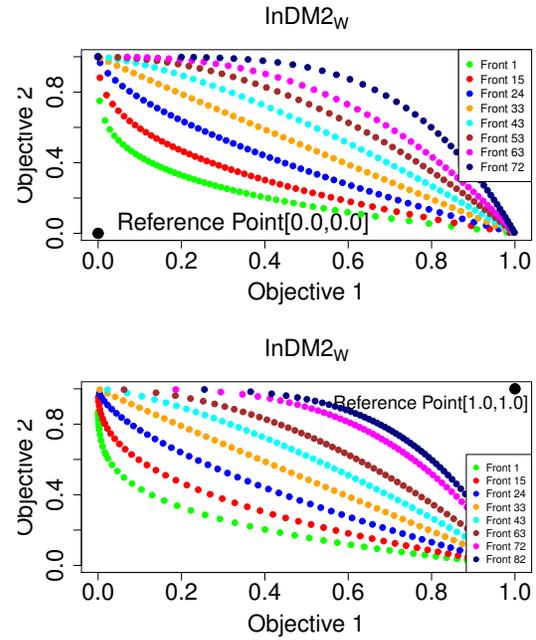


Figura 1: Aproximaciones de región de interés encontradas por InDM2<sub>W</sub> para el problema FD2, utilizando los puntos de referencia (0.0, 0.0) (arriba) y (1.0, 1.0) (abajo).

mostrar los frentes de Pareto aproximados que se generan y otra para guardar estas aproximaciones en archivos. En este estudio, solo se considera una fuente de datos, es decir, no hay ninguna ventaja de utilizar Apache Spark, por lo que hemos configurado el tiempo de ejecución en hebras de manera predeterminada.

El problema de optimización dinámica FDA2 se define con dos objetivos y frentes de Pareto que cambian de forma convexa a cóncava y vice-versa, con conjuntos de Pareto que también cambian con el tiempo.

Para tener una idea de los posibles valores de aspiración (deseables) que cada objetivo puede tener durante el proceso de búsqueda, se ha ejecutado inicialmente InDM2<sub>W</sub> utilizando dos puntos de referencia: el punto ideal (0.0, 0.0) (inalcanzable) y el punto nadir (1.0, 1.0) (alcanzable). Las aproximaciones producidas por InDM2<sub>W</sub> para las regiones de interés de ambos puntos de referencia se muestran en la Figura 1. En esta figura, las leyendas “Front<sub>*i*</sub>” marcan las aproximaciones de la región de interés que se muestran. Cada una de estas leyendas indica implícitamente en qué iteración  $i$  se detectó una mejora significativa en la aproximación generada, en comparación con la anterior mostrada (como se explicó en la Sección III, una nueva aproximación se muestra gráficamente solo en caso de que se haya detectado una mejora significativa con respecto al indicador  $I_{IGD}$ ).

En la Figura 1, podemos observar que cuando la región de interés aproximada es convexa, la distribución de las soluciones en las aproximaciones encontradas es ligeramente más densa en las regiones centrales que en las extremas,

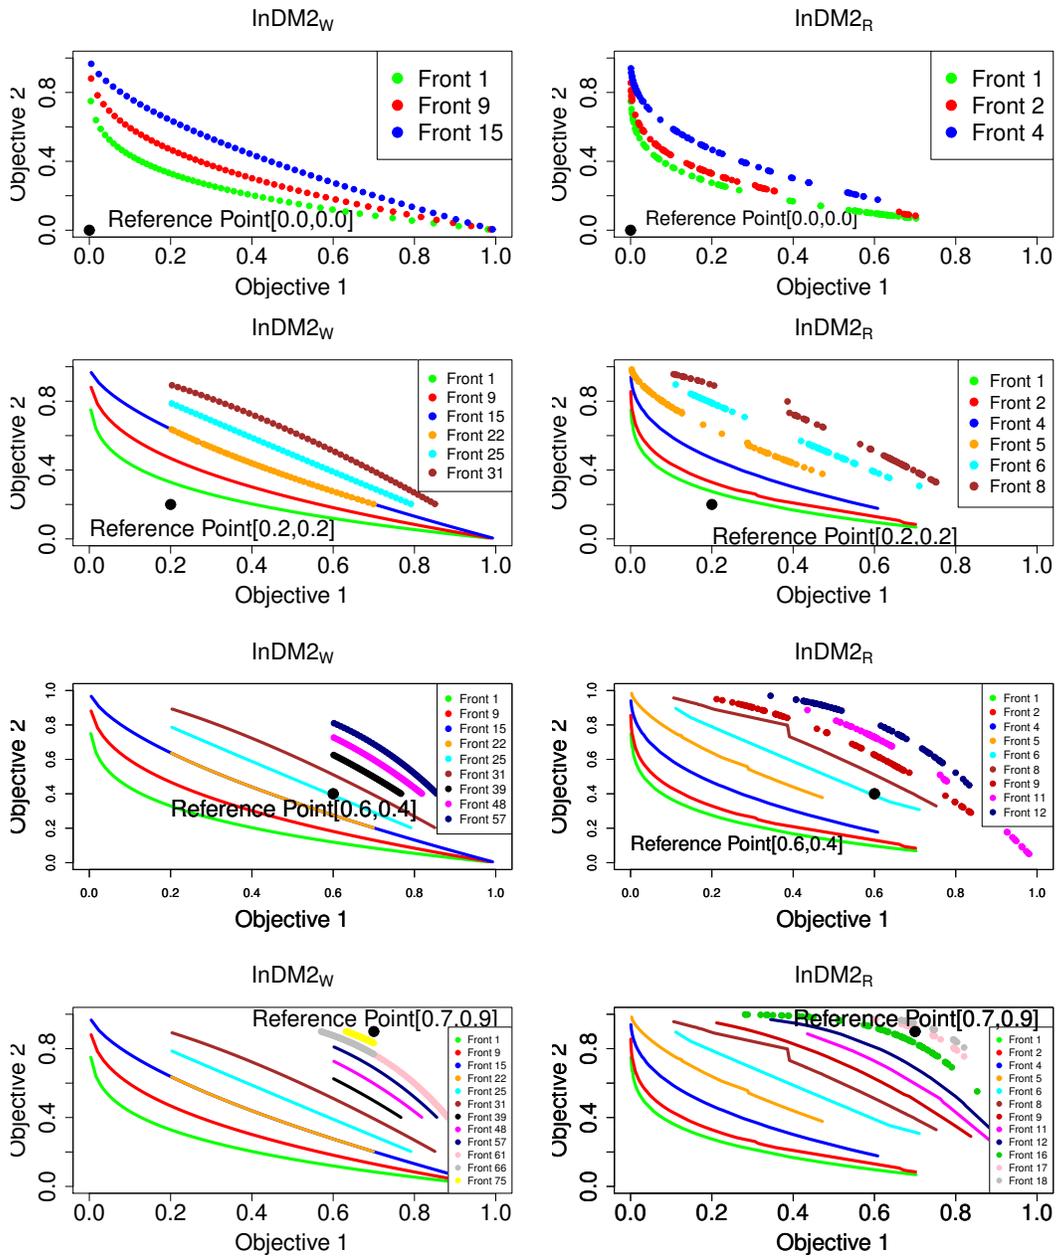


Figura 2: Aproximaciones de la región de interés encontradas por InDM2<sub>W</sub> (izquierda) e InDM2<sub>R</sub> (derecha) para el problema FDA2, utilizando diferentes puntos de referencia.

extendiéndose de manera uniforme cuando la región aproximada tiende a ser más lineal. Esto viene determinado por la distribución de las direcciones de proyección (es decir, vectores de peso) utilizadas internamente en WASF-GA, lo que influye en la distribución de las soluciones encontradas. Para ambos puntos de referencia, InDM2<sub>W</sub> ha podido aproximar la región de interés (que, como se puede ver, es el frente de Pareto completo en ambos casos) al adaptar el proceso de búsqueda a los cambios en el problema.

A continuación, se realizaron pruebas con InDM2<sub>W</sub> e InDM2<sub>R</sub> para FDA2, pero en este caso, se simuló un escenario

realista en el que el decisor modifica sobre la marcha el punto de referencia para indicar la región deseada, varias veces durante el proceso de optimización. La Figura 2 muestra las aproximaciones generadas para los puntos de referencia indicados a lo largo del proceso de optimización de InDM2, para los dos algoritmos base: InDM2<sub>W</sub> y InDM2<sub>R</sub>.

En el proceso interactivo de optimización seguido por InDM2<sub>W</sub>, suponiendo que los rangos del frente de Pareto para problema FDA2 son desconocidos, el decisor seleccionó inicialmente (0.0, 0.0) como primer punto de referencia. Después de observar las tres primeras aproximaciones devueltas por

InDM2<sub>W</sub> en las iteraciones 5, 9 y 15 (véase la gráfica superior izquierda en la Figura 2), el decisor decidió dar un nuevo punto de referencia para reducir la región de interés aproximada y establecerlo en (0.2, 0.2). Podemos observar las nuevas aproximaciones generadas en el segundo gráfico a la izquierda en la Figura 2. En este gráfico, las primeras aproximaciones generadas para el punto de referencia inicial (0.0, 0.0) se muestran con líneas continuas, para poder distinguirlas de las nuevas aproximaciones encontradas para el nuevo punto de referencia (0.2, 0.2), que se muestran con líneas punteadas. Más tarde, el decisor volvió a ajustar la región de interés cambiando el punto de referencia dos veces, indicando (0.6, 0.4) como tercer punto de referencia y (0.7, 0.9) como el cuarto. Respectivamente, los resultados obtenidos para estos dos nuevos puntos de referencia se muestran en las gráficas tercera y cuarta a la izquierda en la misma figura.

Respecto a los frentes obtenidos por InDM2<sub>R</sub> en las gráficas de la derecha en la Figura 2, se puede observar cómo la aproximación de las regiones de interés producidas por esta variante tienen peor diversidad que las generadas por InDM2<sub>W</sub>. Nótese que las soluciones generadas por InDM2<sub>W</sub> siempre pertenecen a la región de interés delimitada por los puntos de referencia, mientras que algunas de las encontradas por InDM2<sub>R</sub> también aproximan zonas fuera de esta región. Esto es consecuencia de las capacidades de búsqueda (convergencia y diversidad con respecto a la región de interés) de WASFGA y R-NSGA-II, lo que evidencia el impacto que puede tener el algoritmo evolutivo basado en preferencias utilizado como base en InDM2.

Según la Figura 2, podemos ver que tres de los puntos de referencia dados en el proceso interactivo de optimización son inalcanzables: (0.0, 0.0), (0.2, 0.2) y (0.6, 0.4); y uno de ellos es alcanzable (0.7, 0.9). Cabe señalar que, en la práctica, la alcanzabilidad de los puntos de referencia no puede conocerse de antemano, y solo se puede saber si son alcanzables o no cuando el algoritmo genera soluciones y se verifica su relación de dominancia con respecto al punto de referencia utilizado.

## V. CONCLUSIONES

En este trabajo se ha descrito InDM2, un nuevo framework algorítmico de optimización dinámica que permite incorporar cualquier metaheurística multi-objetivo basada en puntos de referencia para la articulación de preferencias. Se ha mostrado su funcionamiento mediante la resolución de un problema de optimización dinámica multi-objetivo de benchmarking (FD2). A partir de una serie de visualizaciones, se ha demostrado cómo InDM2 es capaz de generar aproximaciones ajustadas a las preferencias del decisor en tiempo real, tanto si cambia la configuración del problema como si se indican nuevos puntos de referencia (es decir, cambia la región de interés).

Una característica importante de InDM2 viene heredada de su implementación en el framework de jMetalSP, por lo que dispone de procesamiento en streaming mediante Spark de manera transparente. Esto nos permite incorporar múltiples fuentes de datos mediante el uso de proveedores, como sockets, archivos en un directorio, Kafka, Flume o Kinesis. Otra

consecuencia del uso de Spark es la ventaja de trabajar con tecnologías Big Data, lo que nos permite desplegar InDM2 en clusters Hadoop y acceder a datos en HDFS.

Como trabajo futuro, se pretende estudiar el rendimiento de InDM2 en problemas complejos del mundo real, usando preferencias y cambiándolas interactivamente por un decisor experto en el dominio de aplicación.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por los proyectos TIN2017-86049-R, TIN2014-58304-R, ECO2017-88883-R (MECD) y P12-TIC-1519 (PAIDI). J. M. García-Nieto y A. B. Ruiz disfrutaron una beca Post-Doctoral "Captación de Talento para la Investigación", Universidad de Málaga. C. Barba-González dispone de una beca pre-doctoral BES-2015-072209.

## REFERENCIAS

- [1] C. Raquel and X. Yao, "Dynamic multi-objective optimization: A survey of the state-of-the-art," in *Evolutionary Computation for Dynamic Optimization Problems (2013)*, S. Yang and X. Yao, Eds. Springer, 2013, pp. 85–106.
- [2] S. Jiang and S. Yang, "A steady-state and generational evolutionary algorithm for dynamic multiobjective optimization," *IEEE Transactions on Evolutionary Computation*, vol. 21, no. 1, pp. 65–82, 2017.
- [3] X. Chen, D. Zhang, and X. Zeng, "A stable matching-based selection and memory enhanced MOEA/D for evolutionary dynamic multiobjective optimization," in *Int. Conf. on Tools with AI*, 2015, pp. 478–485.
- [4] Y. Jin, C. Yang, J. Ding, and T. Chai, "Reference point based prediction for evolutionary dynamic multiobjective optimization," in *Proc. of the IEEE Cong. on Evol. Comp.*, 2016, pp. 3769–3776.
- [5] A. Muruganatham, K. C. Tan, and P. Vadakkepat, "Evolutionary dynamic multiobjective optimization via kalman filter prediction," *IEEE Transactions on Cybernetics*, vol. 46, no. 12, pp. 2862–2873, 2016.
- [6] M. Farina, K. Deb, and P. Amato, "Dynamic multiobjective optimization problems: test cases, approximations, and applications," *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 5, pp. 425–442, 2004.
- [7] K. Miettinen, *Nonlinear Multiobjective Optimization*. Boston: Kluwer Academic Publishers, 1999.
- [8] A. Jaszkiewicz and J. Branke, "Interactive multiobjective evolutionary algorithms," in *Multiobjective Optimization, Interactive and Evolutionary Approaches*, ser. LNCS, J. Branke, K. Deb, K. Miettinen, and R. Slowinski, Eds., vol. 5252. Springer, 2008, pp. 179–193.
- [9] M. Helbig, K. Deb, and A. Engelbrecht, "Key challenges and future directions of dynamic multi-objective optimisation," in *Proc. of the IEEE Cong. on Evol. Comp.*, 2016, pp. 1256–1261.
- [10] A. B. Ruiz, R. Saborido, and M. Luque, "A preference-based evolutionary algorithm for multiobjective optimization: The weighting achievement scalarizing function genetic algorithm," *Journal of Global Optimization*, vol. 62, no. 1, pp. 101–129, 2015.
- [11] K. Deb, J. Sundar, B. Ubay, and S. Chaudhuri, "Reference point based multi-objective optimization using evolutionary algorithm," *Int. Jour. of Comp. Intel. Res.*, vol. 2, no. 6, pp. 273–286, 2006.
- [12] A. P. Wierzbicki, "The use of reference objectives in multiobjective optimization," in *Multiple Criteria Decision Making, Theory and Applications*, G. Fandel and T. Gal, Eds. Springer, 1980, pp. 468–486.
- [13] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE TEVC*, vol. 6, no. 2, pp. 182–197, 2002.
- [14] C. Barba-Gonzalez, J. M. Garcia-Nieto, A. J. Nebro, J. A. Cordero, J. J. Durillo, I. Navas-Delgado, and J. F. Aldana-Montes, "jMetalSP: A framework for dynamic multi-objective big data optimization," *Applied Soft Computing*, vol. to appear, 2017.
- [15] T. White, *Hadoop: The Definitive Guide*. O'Reilly Media, Inc., 2009.
- [16] A. J. Nebro, A. B. Ruiz, C. Barba-González, J. García-Nieto, M. Luque, and J. F. Aldana-Montes, "InDM2: Interactive dynamic multi-objective decision making using evolutionary algorithms," *Swarm and Evolutionary Computation*, vol. 40, pp. 184 – 195, 2018.
- [17] H. Ishibuchi, H. Masuda, Y. Tanigaki, and Y. Nojima, *Modified Distance Calculation in Generational Distance and Inverted Generational Distance*. Springer International Publishing, 2015, pp. 110–125.

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

**MAEB 6: SESIÓN ESPECIAL:  
METAHEURÍSTICAS EN  
PRODUCCIÓN, LOGÍSTICA Y  
DIRECCIÓN DE OPERACIONES**

**Organizador:**

JOAQUÍN BAUTISTA-VALHONDO







# A GRASP algorithm to optimize Operational Costs and Regularity of Production in mixed-model sequencing problems with forced interruption of operations\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Joaquín Bautista-Valhondo  
*Universidad Politècnica de Catalunya*  
Barcelona, Spain  
joaquin.bautista@upc.edu

Rocío Alfaro-Pozo  
*EAE Business School*  
Barcelona, Spain  
ralfaro@eae.es

**Abstract**—We present a GRASP algorithm to solve a problem that involves the sequencing of mixed products in an assembly line. The objective of the problem is to obtain a manufacturing sequence of models that generates a minimum operational cost with a forced interruption of operations and that is regular in production. The implemented GRASP is compared with other procedures using instances of a case study of the Nissan engine manufacturing plant in Barcelona.

**Index Terms**—GRASP, Bounded Dynamic Programming, Work overload, Operational Cost, Mixed-model Sequencing Problems

# Metaheurísticas constructivas para *Car Sequencing Problem* con Flotas de vehículos especiales

Ignacio Moya\*, Joaquín Bautista†, Manuel Chica\*, Sergio Damas\*, Oscar Cerdón\*

\*Instituto Andaluz Interuniversitario DaSCI (Data Science and Computational Intelligence), Universidad de Granada, España

† Nissan Chair, Universidad Politécnica de Catalunya, España

Emails: imoya@ugr.es, manuelchica@ugr.es, sdamas@ugr.es, joaquin.bautista@upc.edu, ocerdon@decsai.ugr.es

**Resumen**—*Car sequencing problem* (CSP) es un problema tradicional de satisfacción de restricciones que refleja los problemas que surgen cuando una serie de vehículos se introducen en una cadena de producción. Sin embargo no considera vehículos no regulares o fuera de catálogo, pese a que en plantas reales pueden llegar a representar entre el 10 % y el 20 % de la producción. Estos vehículos se distinguen de los regulares por ser bajo pedido, estar orientados al servicio público, y/o requerir componentes poco frecuentes. La extensión *Robust CSP* (r-CSP) sí que considera estos vehículos, modelando la incertidumbre que introducen los vehículos no regulares como escenarios de producción. Para resolver r-CSP proponemos emplear metaheurísticas constructivas que ya han sido efectivas en el CSP tradicional: GRASP y VNS. Evaluamos el rendimiento de estos algoritmos en r-CSP extendiendo las instancias disponibles en la literatura añadiendo la semántica de flotas de vehículos especiales. Nuestros experimentos reflejan que GRASP muestra mejor rendimiento en las instancias más sencillas, mientras que VNS se muestra superior en las más complejas.

**Index Terms**—Metaheurísticas, Líneas de montaje, Secuenciación, Car Sequencing Problem, Flotas de vehículos

## I. INTRODUCCIÓN

*Car Sequencing Problem* (CSP) fue introducido por Parello *et al.* [1] a consecuencia de la transición de la industria hacia la personalización masiva. Es un problema de satisfacción de restricciones que representa las dificultades que surgen al introducir vehículos con opciones diferentes en una misma línea de montaje, transformando restricciones de tiempo, espacio, o técnicas en opciones binarias de modo que todo vehículo requiera de un conjunto arbitrario de estas opciones. Estas opciones se modelan indicando las paradas que pueden aparecer en una línea de montaje si muchos vehículos seguidos requieren una determinada opción, por lo que cada opción se representa usando un ratio de carga. Este ratio se representa como  $p_i/q_i$ , donde  $p$  es el número de vehículos que pueden requerir la opción  $i$  en una secuencia de longitud  $q$  sin causar paradas en la línea. El objetivo del CSP es encontrar una secuencia completa de vehículos que no sobrecargue ninguna opción en ninguna de sus subsecuencias.

Sin embargo el CSP no considera vehículos no regulares o fuera de catálogo [2]. Estos vehículos se distinguen de los regulares por ser bajo pedido, estar orientados al servicio público, y/o requerir componentes poco frecuentes. El impacto de estos vehículos en la cadena genera incertidumbre y afecta a la producción, ya que pueden alcanzar entre el 10 % y el 20 %

de la producción. Una alternativa para tratar esta incertidumbre es definir distintos escenarios de producción que sean realistas.

La extensión *Robust CSP* (r-CSP) [2] sigue este enfoque, donde la demanda se define en distintos planes de producción y el impacto de la variabilidad se mide observando los conflictos que ocurren cuando se cambia de un plan a otro. En este artículo estudiamos la resolución de r-CSP utilizando como referencia el trabajo anterior para el CSP tradicional, que comúnmente se resuelve usando metaheurísticas. Distintas metaheurísticas se han aplicado con éxito al CSP, de las cuales nosotros destacamos las metaheurísticas constructivas GRASP [3] y VNS [4], [5].

El resto del texto sigue la siguiente estructura. La Sección II revisa la bibliografía relevante relacionada con la resolución del CSP tradicional. Después presentamos brevemente la formalización del r-CSP en la Sección III. La Sección IV describe las metaheurísticas empleadas en nuestros experimentos. En la Sección V presentamos la configuración y los resultados de nuestros experimentos para el r-CSP. Por último, en la Sección VI presentamos nuestras conclusiones.

## II. TRABAJO RELACIONADO

Existen diferentes alternativas para resolver el CSP tradicional. Encontramos varios métodos exactos basados en programación con restricciones [6], [7], *integer programming* [8], algoritmos de ramificación y poda [9], o *beam search* [10], [11]. También encontramos muchos ejemplos de resolución usando metaheurísticas [5], [12], [13], [14], [15]. Todos estos métodos se suelen comparar usando el *framework* de referencia CSPLib [16].

De entre los distintos trabajos que utilizan metaheurísticas, podemos destacar los métodos basados en búsqueda local, VNS y GRASP. De entre los trabajos que emplean búsqueda local, el trabajo de Puchta y Gottlieb [17] es especialmente relevante dado que introduce nuevos operadores que han sido empleados posteriormente en otros trabajos [3], [5], [12], [13]. Uno de estos operadores, llamado operador de inversión o *Lin2Opt* se ha convertido en un operador recurrente. Los métodos de búsqueda local normalmente incluyen heurísticas voraces para construir la solución inicial, de las cuales encontramos que la propuesta por Gottlieb *et al.* [12] es la más empleada [5], [13], [14], [18], [19].

En el caso de VNS y GRASP, las contribuciones más relevantes se aplican a extensiones del CSP tradicional. En



el caso de VNS, destacamos el trabajo propuesto de Ribeiro *et al.* [4]. Su versión de VNS combinada con ILS terminó en segunda posición en el ROADEF'2005 [20], donde el problema a resolver era una extensión del CSP tradicional que incluye nuevas restricciones relacionadas con la pintura. Hemos incluido algunas de las características de su trabajo en nuestro diseño de VNS, como el uso del operador de inserción (explicado en la Sección IV-C) como operador en la perturbación de la solución. En el caso del GRASP podemos encontrar trabajos donde se utiliza para resolver extensiones del CSP tradicional [3], por lo que incluimos estos diseños en nuestro estudio.

### III. DESCRIPCIÓN DEL MODELO

En esta sección describimos las particularidades del CSP con flotas de vehículos especiales (r-CSP). Este modelo sigue las siguientes hipótesis de trabajo:

1. Hay dos conjuntos separados de familias de vehículos: los regulares  $I_X$  y los especiales  $I_{X'}$ .
2. Existe una demanda de vehículos regulares  $D_X$  fija para cada plan de producción  $\varepsilon \in E$ .
3. Existe una demanda de vehículos especiales  $D_{X'}$  fija para cada plan de producción  $\varepsilon \in E$ .
4. La demanda total de vehículos  $T (T \equiv D \equiv D_X + D_{X'})$ , se respeta en todos los planes de producción  $\varepsilon \in E$ .
5. La demanda para cada vehículo regular  $d_i, i \in I_X$  es la misma para cada plan de producción  $\varepsilon \in E$ . Esto es,  $d_{i,\varepsilon} = d_i, \forall \varepsilon \in E$ .
6. La demanda de cada vehículo especial  $i \in I_{X'}$ , puede cambiar para dos planes de producción distintos  $\{\varepsilon, \varepsilon'\} \subseteq E$ .
7. Los cambios en la cadena de producción deberían ser tan pocos como sea posible, por lo que las secuencias de producción  $\pi_\varepsilon(T)$  y  $\pi_{\varepsilon'}(T)$  deberían ser lo más similares posible para cada par de planes  $\{\varepsilon, \varepsilon'\} \subseteq E$ . Esto es:  $\pi_\varepsilon(T) \approx \pi_{\varepsilon'}(T), \forall \{\varepsilon, \varepsilon'\} \subseteq E$ .
8. Cada vehículo regular mantendrá la misma posición en todas las secuencias  $\pi_\varepsilon(T), \forall \varepsilon \in E$ .

A continuación incluimos la definición formal de r-CSP en el ámbito de programación lineal entera mixta. También incluimos un conjunto de restricciones que cualquier secuencia válida debe cumplir. Las restricción (1) impone que solo un vehículo (regular o especial) puede asignarse en cada ciclo de producción  $t \in [1, T]$  para todos los planes de producción  $\varepsilon \in E$ . Las restricciones (2) y (3) fuerzan a que se satisfaga la demanda de vehículos regulares ( $I_X$ ) y especiales ( $I_{X'}$ ) en cada plan de producción. La restricción (4) determina la producción acumulada de la clase de vehículos regulares  $i \in I_X$  hasta el ciclo de fabricación  $t$ . La restricción (5) es análoga a la anterior, referida a los vehículos especiales. Las restricciones (6) y (7) imponen que el número de veces que se requiere la opción  $j \in J$  de manera consecutiva en cualquier ciclo de producción  $t \in [1, T]$  para todo plan de producción  $\varepsilon \in E$  no supere su ratio  $p/q$ . Las restricciones (8), (9), y (10) definen respectivamente las variables binarias  $x_{i,t}$ ,  $x_{i,t,\varepsilon}$ ,

y  $z_{j,t,\varepsilon}$ . Finalmente, la restricción (11) fija un valor nulo para las variables  $Y_{j,0,\varepsilon} (\forall j \in J, \forall \varepsilon \in E)$  en el ciclo virtual  $t = 0$ .

$$\sum_{i \in I_X} x_{i,t} + \sum_{i \in I_{X'}} x_{i,t,\varepsilon} = 1, \forall t \in [1, T], \forall \varepsilon \in E \quad (1)$$

$$\sum_{t \in [1, T]} x_{i,t} = d_i \forall i \in I_X \quad (2)$$

$$\sum_{t \in [1, T]} x_{i,t,\varepsilon} = d_{i,\varepsilon}, \forall i \in I_{X'}, \forall \varepsilon \in E \quad (3)$$

$$X_{i,t} - \sum_{\tau \in [1, t]} x_{i,\tau} = 0, \forall i \in I_X, \forall t \in [1, T] \quad (4)$$

$$X_{i,t,\varepsilon} - \sum_{\tau \in [1, t]} x_{i,\tau,\varepsilon} = 0, \quad (5)$$

$$\forall i \in I_{X'}, \forall t \in [1, T], \forall \varepsilon \in E$$

$$Y_{j,t,\varepsilon} - \sum_{i \in I_X} n_{j,i} X_{i,t} - \sum_{i \in I_{X'}} n_{j,i} X_{i,t,\varepsilon} = 0, \quad (6)$$

$$\forall j \in J, \forall t \in [1, T], \forall \varepsilon \in E$$

$$Y_{j,t,\varepsilon} - Y_{j,t-q_j,\varepsilon} \leq p_j + T \cdot z_{j,t,\varepsilon}, \quad (7)$$

$$\forall j \in J, \forall t \in [q_j, T], \forall \varepsilon \in E$$

$$x_{i,t} \in \{0, 1\}, \forall i \in I_X, \forall t \in [1, T] \quad (8)$$

$$x_{i,t,\varepsilon} \in \{0, 1\}, \forall i \in I_{X'}, \forall t \in [1, T], \forall \varepsilon \in E \quad (9)$$

$$z_{j,t,\varepsilon} \in \{0, 1\}, \forall j \in J, \forall t \in [q_j, T], \forall \varepsilon \in E \quad (10)$$

$$Y_{j,0,\varepsilon} = 0, \forall j \in J, \forall \varepsilon \in E \quad (11)$$

r-CSP define multiseuencias  $\vec{\pi}(E, T)$  compuestas de secuencias individuales  $\pi_\varepsilon(T) = (\pi_{1,\varepsilon}, \dots, \pi_{T,\varepsilon})$  para cada plan de producción  $\varepsilon \in E$ , como se muestra en la ecuación (12). Los vehículos regulares  $i \in I$  se relacionan con los elementos  $\pi_{t,\varepsilon} (\forall t \in [1, T], \forall \varepsilon \in E)$  de la multiseuencia  $\vec{\pi}(E, T)$  por las variables binarias  $x_{i,t} (\forall i \in I_X, \forall t \in [1, T])$  y  $x_{i,t,\varepsilon} (\forall i \in I_{X'}, \forall t \in [1, T], \forall \varepsilon \in E)$ , como se define en las ecuaciones (13) y (14). Debemos remarcar que todo vehículo regular ( $i \in I_X$ ) mantiene su posición en la secuencia para cada plan de producción, pero las posiciones ocupadas por vehículos especiales dependen del plan de producción  $\varepsilon \in E$ . De este modo podemos decir que toda secuencia  $\pi_\varepsilon(T)$  tiene un componente común (los vehículos regulares) y un componente exclusivo (sus vehículos especiales).

$$\pi_\varepsilon(T) = \left\{ \begin{array}{c} \pi_1(T) \\ \pi_2(T) \\ \dots \\ \pi_\varepsilon(T) \\ \dots \\ \pi_{|E|}(T) \end{array} \right\} = \left\{ \begin{array}{c} (\pi_{1,1}, \dots, \pi_{t,1}, \dots, \pi_{T,1}) \\ (\pi_{1,2}, \dots, \pi_{t,2}, \dots, \pi_{T,2}) \\ \dots \\ (\pi_{1,\varepsilon}, \dots, \pi_{t,\varepsilon}, \dots, \pi_{T,\varepsilon}) \\ \dots \\ (\pi_{1,|E|}, \dots, \pi_{t,|E|}, \dots, \pi_{T,|E|}) \end{array} \right\} \quad (12)$$

$$x_{i,t} = 1 \Rightarrow \pi_{t,\varepsilon} = i, \forall i \in I_X, \forall t \in [1, T], \forall \varepsilon \in E \quad (13)$$

$$x_{I,t} = 1 \Rightarrow \pi_{t,\varepsilon} = i, \forall i \in I_{X_I}, \forall t \in [1, T], \forall \varepsilon \in E \quad (14)$$

Si siguiendo esta formulación definimos la función objetivo para r-CSP. Esta función, que mostramos en la ecuación (15), minimiza el número de violaciones de restricciones para las opciones  $j \in J$  usando sus ratios de carga  $p_j/q_j$  para todos los planes de producción  $\varepsilon \in E$ . Usando este enfoque tratamos r-CSP como un problema de satisfacción de restricciones y conectamos con la formulación original de Parello *et al.* [1].

$$\begin{aligned} \min Z &= \sum_{j \in J} \sum_{t \in [q_j, T]} \sum_{\varepsilon \in E} z_{j,t,\varepsilon} \\ &\Leftrightarrow \max Z_I = \sum_{j \in J} \sum_{t \in [q_j, T]} \sum_{\varepsilon \in E} (1 - z_{j,t,\varepsilon}) \end{aligned} \quad (15)$$

#### IV. MÉTODOS

Como ya hemos anticipado, existen distintos casos de éxito de la aplicación de metaheurísticas al CSP tradicional [4], [12], [13], [17], [21]. En muchas de estos casos se aplican metaheurísticas constructivas [22], por lo que proponemos resolver r-CSP también con estos métodos. En concreto, hemos elegido GRASP y VNS.

##### A. GRASP

Nuestro diseño de *Greedy Randomized Adaptive Search Procedure* (GRASP) [23] está basado en la heurística propuesta por Gottlieb *et al.* [12]. De este modo, la lista de candidatos para la fase constructiva se compone en tres etapas. En el primer paso, se descartan los vehículos que violarían alguna restricción de carga  $p/q$ , salvo que no existan vehículos que no violen alguna restricción, que en ese caso deberán incluir el mínimo de nuevas violaciones posible. En el segundo paso, si existe más de un elemento en la lista (muy posible sobretodo en los primeros pasos), esos elementos se ordenan según su valor heurístico usando la heurística de Gottlieb *et al.* [12]. De este modo se favorece incluir primero los vehículos que incluyen opciones más restrictivas. Finalmente la lista de candidatos se trunca dependiendo del parámetro  $\alpha \in (0, 1]$ , dejando en la lista los elementos con mejor valor heurístico. La selección final en este paso de la fase constructiva será un elemento aleatorio de la lista de candidatos resultante. Exponemos la fase de refinado posterior usando búsqueda local en la Sección IV-C.

##### B. VNS

Nuestra implementación de *Variable Neighborhood Search* (VNS) [24] construye su solución inicial siguiendo una estrategia voraz basada en la heurística de Gottlieb *et al.* [12]. A diferencia del diseño usado por GRASP, en este caso el proceso es determinista y siempre se elige el vehículo que incluya el menor número de violaciones posible con el mejor valor de la heurística.

Con respecto al diseño de la fase de perturbación de la solución, usamos un operador distinto al que después se utiliza para la fase de refinado. En concreto elegimos utilizar un operador de inserción, que se aplica  $k$  veces durante la fase de perturbación donde  $k$  es igual a la iteración actual del algoritmo. Por ejemplo, con  $k = 3$  aplicamos tres veces el operador de manera secuencial. Este operador se describe en detalle junto con el resto de operadores de búsqueda local en la Sección IV-C.

##### C. Búsqueda local

Elegimos nuestros operadores para la búsqueda local basándonos en trabajo previo [12], [17] y el resultado de nuestros experimentos. Estos operadores son: *Swap*, *Inserción*, y *Inversión*. Para mostrar como estos operadores modifican una secuencia dada usaremos como referencia la cadena  $\pi$  descrita en la Ecuación 16. El operador de *Swap* intercambia dos posiciones aleatorias en una secuencia. En la Ecuación 17 se puede ver el resultado de aplicar el operador de *Swap* a la cadena  $\pi$ , intercambiando los elementos de los índices 3 y 7. El operador de *Inserción* selecciona un índice aleatoriamente y lo mueve a otra posición aleatoria de la cadena, desplazando las posiciones intermedias de manera que mantengan su orden en la secuencia. En la Ecuación 18 el operador de *Inserción* mueve el elemento en la posición 5 a la posición 9. El operador de *Inversión* invierte una subcadena definida por dos índices seleccionados aleatoriamente. En la Ecuación 19 se muestra cómo el operador de *Inversión* invierte una subcadena de  $\pi$  entre las posiciones 4 y 6.

$$\pi = 5, 3, 4, 2, 3, 4, 1, 5, 2, 0 \quad (16)$$

$$\pi_{Swap} = 5, 3, \mathbf{1}, 2, 3, 4, \mathbf{4}, 5, 2, 0 \quad (17)$$

$$\pi_{Insert} = 5, 3, 4, 2, 4, 1, 5, 2, \mathbf{3}, 0 \quad (18)$$

$$\pi_{Invert} = 5, 3, 4, \mathbf{4}, \mathbf{3}, \mathbf{2}, 1, 5, 2, 0 \quad (19)$$

Independientemente del operador, nuestra búsqueda local siempre se mueve al primer vecino que mejore la solución (*primer-mejor*). De este modo, en cada paso de la búsqueda local se genera y evalúa un vecino aleatorio de la solución actual, aceptándolo si mejora a la anterior y deshaciendo el cambio si no. Nuestra búsqueda local aplica dos operadores de manera secuencial: primero explora el espacio de búsqueda usando *Swap* hasta que la búsqueda termina; después se repite el proceso utilizando el operador de *Inversión*.



## V. EXPERIMENTACIÓN

### A. Configuración

Comparamos el rendimiento de las metaheurísticas seleccionadas usando las instancias publicadas en CSPLib [16], que es el *benchmark* generalmente utilizado por la comunidad del CSP [12], [13], [14]. Este benchmark contiene instancias con diferentes grados de complejidad que se podrían dividir en tres categorías: las factibles, las clásicas y las avanzadas. Las instancias factibles son un conjunto de 70 instancias de 200 vehículos con 5 opciones y entre 17 y 30 clases. Podemos argumentar que estas instancias son las más básicas dado que están diseñadas para ser factibles. Estas instancias están divididas en grupos de 10 según el porcentaje de requerimiento de sus opciones. Las instancias menos exigentes de esta categoría tienen un 60% y los distintos grupos de instancias aumentan su complejidad gradualmente hasta un 90%. Las instancias clásicas [16] son un grupo de 9 instancias con 100 vehículos con 5 opciones y entre 18 y 24 clases. Este grupo de instancias es más complejo porque sólo 4 de ellas son factibles, dado que su porcentaje de requerimiento de sus opciones está cercano al 100%. Finalmente las instancias avanzadas, propuestas por [8], son 30 secuencias de 200, 300, y 400 vehículos. Estas instancias tienen configuraciones de opciones y clases similares a las instancias clásicas. Igual que en el caso de las instancias clásicas, las instancias avanzadas están diseñadas para tener un porcentaje de requerimiento muy alto y para la mayoría de ellas no se conoce una solución factible [15].

Como estas instancias no consideran demanda parcial incierta, extendemos su semántica generando apéndices que incluyan flotas de vehículos especiales para las instancias ya existentes. De esta manera maximizamos la compatibilidad con los trabajos anteriores. El enfoque que seguimos es el siguiente: para cada instancia existente, consideramos como no regulares el 20% de sus clases de vehículos. La suma de la demanda original de los vehículos que pasan a tratarse como no regulares será la demanda de vehículos especiales en el plan de producción de referencia. En concreto, las clases de vehículos no regulares serán las últimas clases definidas en la instancia original. Por ejemplo, tomando secuencia original con 10 clases, las clases de vehículos 1 a 8 seguirán siendo vehículos regulares y las clases 9 y 10 serán consideradas no regulares. De este modo, la demanda de vehículos que consideran flotas de vehículos especiales depende de la demanda para las clases 9 y 10. Para terminar, se generan aleatoriamente 10 planes de producción utilizando una distribución uniforme. Continuando el ejemplo anterior, si la demanda original de las clases 9 y 10 era de 20 vehículos cada una, la suma de ambas será la demanda del plan de referencia y se generan 10 combinaciones aleatorias de 40 vehículos en total.

En cuanto a los cálculos de fitness, en el caso del CSP tradicional los valores de fitness representan el número de violaciones de restricciones  $p/q$  en una secuencia. Este es un caso especial de la función objetivo definida en la Ecuación 15 con un único plan de producción (i.e.  $|E| = 1$ ). Podemos deno-

minar a esta función objetivo  $regular(\pi_\varepsilon)$ . Calcular el fitness para  $|E| > 1$  implica generar y calcular cada combinación de planes de producción y vehículos no regulares contando las nuevas violaciones ( $\forall \varepsilon \in E$ ). Dado que generar cada posible combinación para todas las secuencias implicaría tiempos de ejecución muy costosos, en su lugar optamos por una solución intermedia: simular este valor siguiendo un enfoque similar a las *simheurísticas* [25]. De este modo aproximamos el valor generando aleatoriamente  $|M|$  secuencias posibles para cada plan de producción partiendo de la secuencia encontrada usando el plan de referencia  $\pi_\varepsilon$  y calculamos la media del mínimo de violaciones para cada plan  $\varepsilon \in E$ . La función  $fleets(\pi_\varepsilon)$ , definida en la Ecuación 20, es por tanto una aproximación para calcular la función objetivo de r-CSP (definida en la Ecuación 15 de la Sección III). Nuestra función de fitness final para resolver r-CSP combina el número de violaciones sobre el plan de referencia con la aproximación de las violaciones de las flotas de vehículos especiales usando el parámetro  $\theta$ . Este parámetro  $\theta$  se incluye para potenciar la relevancia del plan de referencia con respecto al resto de planes de producción. Ajustamos los parámetros  $\theta$  y  $|M|$  durante la experimentación y finalmente se fijan a  $\theta = 0,6$  y  $|M| = 30$ . En la Ecuación 21 mostramos la función objetivo final que utilizamos en nuestros experimentos ( $fitness(\pi_\varepsilon)$ ).

$$fleets(\pi_\varepsilon) = \frac{\min \sum_{j \in J} \sum_{t \in [q_j, T]} \sum_{\varepsilon \in E} z_{j,t,\varepsilon}}{|M|}, \quad \forall m \in M \quad (20)$$

$$fitness(\pi_\varepsilon) = \theta * regular(\pi_\varepsilon) + (1 - \theta) * fleets(\pi_\varepsilon) \quad (21)$$

Tanto GRASP como VNS ejecutan durante su búsqueda local un máximo de 10,000 pasos, y contemplan 400 iteraciones respectivamente. De este modo, nuestra experimentación fija un criterio de parada de 4,000,000 evaluaciones para las metaheurísticas, que se ejecutan 30 veces utilizando diferentes semillas. Además, fijamos el parámetro  $\alpha = 0,15$  para las ejecuciones de GRASP. En cuanto a la implementación, hemos implementado cada metaheurística en Java y hemos empleado JAMES [26] para la búsqueda local.

### B. Comparación algorítmica para el r-CSP

En esta sección discutimos el rendimiento de las metaheurísticas sobre las instancias modificadas para incluir flotas de vehículos especiales. Por razones de espacio los resultados sobre estas instancias se muestran divididos en las Tablas I (instancias básicas desde 60-01 hasta 85-10) y II (instancias básicas entre 90-01 y 90-10, instancias clásicas  $p^*$ , e instancias avanzadas  $pb_{200}^*$ ,  $pb_{300}^*$ , y  $pb_{400}^*$ ).

En la Tabla I vemos que prácticamente todos los valores resaltados son de GRASP, tanto en mínimo valor como en valor promedio de *fitness*. La superioridad de GRASP en estas instancias podría deberse a la baja carga de sus opciones. Además con la configuración de parámetros elegida puede que



Tabla I  
VALORES MÍNIMOS Y PROMEDIO DE LAS 30 EJECUCIONES DE CADA  
METAHEURÍSTICA APLICADA A LAS INSTANCIAS ENTRE 60-01 Y 85-10.

Instancias	GRASP		VNS	
	Min	Med	Min	Med
60-01	<b>3.08</b>	<b>3.63</b>	4.64	5.97
60-02	<b>59.48</b>	<b>60.50</b>	62.92	63.73
60-03	<b>4.32</b>	<b>4.66</b>	6.00	6.82
60-04	<b>30.56</b>	<b>31.23</b>	31.28	32.87
60-05	<b>1.48</b>	<b>2.40</b>	3.44	4.62
60-06	<b>2.24</b>	<b>3.01</b>	2.68	3.56
60-07	<b>1.72</b>	<b>2.18</b>	2.92	3.74
60-08	<b>3.52</b>	<b>4.22</b>	6.56	7.71
60-09	<b>2.96</b>	<b>3.44</b>	3.88	5.03
60-10	<b>2.92</b>	<b>3.71</b>	9.24	10.81
65-01	<b>6.28</b>	<b>7.04</b>	7.24	7.82
65-02	<b>59.96</b>	<b>60.72</b>	62.68	62.68
65-03	<b>5.60</b>	<b>6.24</b>	9.68	11.02
65-04	<b>26.60</b>	<b>27.57</b>	27.32	29.10
65-05	<b>4.96</b>	<b>5.53</b>	5.52	7.42
65-06	<b>5.20</b>	<b>5.99</b>	8.76	10.13
65-07	<b>5.08</b>	<b>5.68</b>	7.60	9.05
65-08	<b>5.24</b>	<b>5.99</b>	8.04	9.07
65-09	<b>2.32</b>	<b>2.75</b>	3.60	4.59
65-10	<b>4.00</b>	<b>4.99</b>	7.16	9.43
70-01	<b>7.24</b>	<b>8.56</b>	11.20	11.91
70-02	<b>58.56</b>	<b>60.03</b>	61.04	62.07
70-03	<b>10.88</b>	<b>11.53</b>	12.76	13.60
70-04	<b>10.48</b>	<b>11.33</b>	11.04	11.94
70-05	<b>12.28</b>	<b>12.81</b>	14.88	15.96
70-06	<b>3.28</b>	<b>3.94</b>	6.56	7.38
70-07	<b>8.92</b>	<b>9.86</b>	12.12	13.88
70-08	<b>8.32</b>	<b>8.99</b>	9.44	10.46
70-09	<b>6.48</b>	<b>7.52</b>	7.36	10.01
70-10	<b>7.84</b>	<b>8.82</b>	11.16	13.88
75-01	<b>10.80</b>	<b>11.28</b>	11.84	13.22
75-02	<b>106.32</b>	<b>108.29</b>	109.92	113.16
75-03	<b>15.88</b>	<b>16.42</b>	17.40	18.74
75-04	<b>17.64</b>	<b>19.02</b>	18.60	20.34
75-05	<b>8.92</b>	<b>9.83</b>	10.80	11.92
75-06	<b>9.52</b>	<b>10.08</b>	12.40	13.84
75-07	<b>14.04</b>	<b>14.86</b>	14.96	16.77
75-08	<b>17.96</b>	<b>19.12</b>	20.52	21.65
75-09	<b>6.64</b>	<b>7.95</b>	9.12	10.52
75-10	<b>11.72</b>	<b>12.97</b>	16.52	18.39
80-01	<b>6.40</b>	<b>7.11</b>	7.80	8.41
80-02	<b>110.92</b>	<b>112.89</b>	113.12	115.61
80-03	<b>13.24</b>	<b>13.82</b>	15.64	16.67
80-04	<b>34.72</b>	<b>35.68</b>	34.88	36.65
80-05	<b>19.16</b>	<b>20.09</b>	23.28	24.79
80-06	<b>9.44</b>	<b>10.40</b>	12.76	14.29
80-07	<b>15.40</b>	<b>16.36</b>	19.20	20.86
80-08	<b>13.60</b>	<b>14.68</b>	14.48	15.82
80-09	<b>86.40</b>	<b>87.62</b>	89.40	92.24
80-10	<b>12.28</b>	<b>13.79</b>	15.64	16.53
85-01	<b>6.20</b>	<b>7.02</b>	7.76	8.63
85-02	<b>29.76</b>	<b>30.53</b>	32.56	34.16
85-03	<b>36.76</b>	<b>37.64</b>	38.40	41.20
85-04	<b>23.48</b>	<b>24.02</b>	26.12	27.24
85-05	<b>50.20</b>	<b>51.20</b>	52.08	53.26
85-06	61.84	<b>62.65</b>	<b>61.16</b>	62.94
85-07	<b>11.60</b>	<b>12.15</b>	13.80	14.51
85-08	<b>19.72</b>	<b>20.56</b>	21.00	22.00
85-09	<b>55.04</b>	<b>56.34</b>	55.00	56.93
85-10	<b>22.20</b>	<b>23.73</b>	25.72	27.85

Tabla II  
VALORES MÍNIMOS Y PROMEDIO DE LAS 30 EJECUCIONES DE CADA  
METAHEURÍSTICA APLICADA A LAS INSTANCIAS 90-\*, CLÁSICAS, 200-\*,  
300-\*, Y 400-\*.

Instancias	GRASP		VNS	
	Min	Med	Min	Med
90-01	<b>12.76</b>	<b>14.27</b>	13.60	14.35
90-02	<b>26.28</b>	<b>27.37</b>	26.44	30.13
90-03	<b>18.52</b>	<b>21.91</b>	21.36	23.05
90-04	<b>13.40</b>	<b>14.35</b>	14.28	15.35
90-05	42.40	44.85	<b>40.52</b>	<b>42.15</b>
90-06	<b>61.80</b>	<b>63.43</b>	66.56	69.52
90-07	26.48	28.57	<b>25.92</b>	<b>27.22</b>
90-08	<b>65.60</b>	<b>67.01</b>	67.20	68.80
90-09	<b>44.20</b>	<b>45.46</b>	45.48	46.80
90-10	<b>38.04</b>	<b>38.97</b>	39.08	40.22
p10_93	15.88	17.53	<b>10.72</b>	<b>11.87</b>
p16_81	10.28	11.07	<b>5.52</b>	<b>6.65</b>
p19_71	9.52	10.94	<b>7.08</b>	<b>7.59</b>
p21_90	4.28	5.75	<b>3.20</b>	<b>3.88</b>
p26_82	12.80	13.53	<b>10.16</b>	<b>10.98</b>
p36_92	12.68	13.36	<b>10.32</b>	<b>10.93</b>
p41_66	6.40	7.29	<b>6.08</b>	<b>7.03</b>
p4_72	10.08	11.17	<b>6.20</b>	<b>7.35</b>
p6_76	7.28	7.83	<b>7.16</b>	<b>7.58</b>
pb_200_01	53.40	54.83	<b>46.76</b>	<b>48.84</b>
pb_200_02	20.68	22.87	<b>14.68</b>	<b>15.73</b>
pb_200_03	43.32	46.02	<b>38.40</b>	<b>39.86</b>
pb_200_04	25.64	27.65	<b>19.72</b>	<b>21.25</b>
pb_200_05	23.44	24.75	<b>20.92</b>	<b>22.07</b>
pb_200_06	24.52	25.70	<b>20.96</b>	<b>22.09</b>
pb_200_07	13.76	15.57	<b>7.84</b>	<b>8.23</b>
pb_200_08	30.28	32.29	<b>27.24</b>	<b>29.33</b>
pb_200_09	20.44	22.35	<b>17.72</b>	<b>18.32</b>
pb_200_10	34.76	37.17	<b>34.32</b>	<b>35.44</b>
pb_300_01	71.36	73.56	<b>57.88</b>	<b>60.97</b>
pb_300_02	44.16	47.69	<b>30.00</b>	<b>32.87</b>
pb_300_03	<b>49.76</b>	<b>52.42</b>	52.76	54.17
pb_300_04	55.08	57.41	<b>44.52</b>	<b>47.26</b>
pb_300_05	71.52	74.93	<b>70.40</b>	<b>74.24</b>
pb_300_06	44.16	47.46	<b>41.12</b>	<b>44.09</b>
pb_300_07	62.00	64.68	<b>45.52</b>	<b>51.22</b>
pb_300_08	38.40	41.16	<b>27.28</b>	<b>29.87</b>
pb_300_09	46.56	48.17	<b>41.60</b>	<b>43.82</b>
pb_300_10	113.16	116.20	<b>106.48</b>	<b>110.25</b>
pb_400_01	84.84	89.38	<b>79.12</b>	<b>82.13</b>
pb_400_02	70.64	74.18	<b>65.20</b>	<b>67.85</b>
pb_400_03	56.12	57.66	<b>47.12</b>	<b>49.85</b>
pb_400_04	106.04	108.47	<b>95.44</b>	<b>97.38</b>
pb_400_05	61.36	65.55	<b>47.76</b>	<b>52.32</b>
pb_400_06	87.16	89.49	<b>72.32</b>	<b>75.24</b>
pb_400_07	83.72	88.40	<b>73.84</b>	<b>78.20</b>
pb_400_08	45.80	48.24	<b>40.60</b>	<b>43.71</b>
pb_400_09	145.52	150.82	<b>131.64</b>	<b>137.13</b>
pb_400_10	126.72	132.31	<b>120.28</b>	<b>124.20</b>



GRASP tenga algo más de diversidad que VNS, al cual la heurística voraz de su fase constructiva puede estar guiando a un óptimo local donde el plan de referencia es factible. Esta explicación es consistente con los resultados de la Tabla II, donde GRASP reduce mucho su rendimiento en favor de VNS. En este caso VNS consigue prácticamente la mayoría de los mejores resultados desde p10\_93 en adelante. Dado que estas instancias tienen un requerimiento de sus opciones mayor, se incrementa la importancia de encontrar una secuencia factible para el plan de referencia. Además GRASP sólo consigue uno de los mejores resultados en instancias que tengan más de 200 vehículos, lo que podría indicar que la escalabilidad del problema afecta a su rendimiento.

## VI. CONCLUSIONES

En este artículo hemos propuesto cómo solucionar r-CSP usando metaheurísticas constructivas, específicamente GRASP y VNS. Para ello hemos presentado nuestra propuesta para generar instancias de r-CSP a partir de las instancias de CSP tradicionales, que hemos tomado del benchmark de referencia CSPLib. Los resultados al aplicar las metaheurísticas usando las instancias extendidas para r-CSP muestran que GRASP es más competitivo en las instancias para las cuales es más sencillo encontrar una secuencia factible para el plan de referencia. En cambio pierde efectividad gradualmente al incrementar la dificultad de las instancias y finalmente es sobrepasado por VNS.

Nuestro trabajo futuro se centrará en incluir nuevas metaheurísticas constructivas como *Ant Colony Optimization* [27], que podrían además combinarse con nuestros procedimientos de búsqueda local ya presentados. Futuras extensiones de nuestro trabajo también considerarán la definición de métricas de robustez más avanzadas que evalúen la calidad de las soluciones más allá de la violación de restricciones del CSP tradicional.

## AGRADECIMIENTOS

Este trabajo está financiado por el Ministerio de Economía y Competitividad bajo los proyectos NEWSOCO (ref. TIN2015-67661-P) y FHI-SELM2 (ref. TIN2014-57497-P), incluyendo Fondos Europeos de Desarrollo Regional (ERDF).

## REFERENCIAS

- [1] B. D. Parrello, W. C. Kabat, and L. Vos, "Job-shop scheduling using automated reasoning: A case study of the car-sequencing problem," *Journal of Automated Reasoning*, vol. 2, no. 1, pp. 1–42, 1986.
- [2] J. Bautista Valhondo, "Modelos y métricas para la versión robusta del car sequencing problem con flotas de vehículos especiales," *Dirección y organización*, vol. 60, no. 2016, pp. 57–65, 2016.
- [3] J. Bautista, J. Pereira, and B. Adenso-Díaz, "A GRASP approach for the extended car sequencing problem," *Journal of Scheduling*, vol. 11, no. 1, pp. 3–16, 2008.
- [4] C. C. Ribeiro, D. Aloise, T. F. Noronha, C. Rocha, and S. Urrutia, "An efficient implementation of a VNS/ILS heuristic for a real-life car sequencing problem," *European Journal of Operational Research*, vol. 191, no. 3, pp. 596–611, 2008.
- [5] U. Golle, "Fitness landscape analysis and design of metaheuristics for car sequencing," *On the Car Sequencing Problem: Analysis and Solution Methods*, p. 100, 2011.
- [6] M. Bergen, P. Van Beek, and T. Carchrae, "Constraint-based vehicle assembly line sequencing," *Advances in Artificial Intelligence*, pp. 88–99, 2001.
- [7] M. Siala, E. Hebrard, and M.-J. Huguet, "A study of constraint programming heuristics for the car-sequencing problem," *Engineering Applications of Artificial Intelligence*, vol. 38, pp. 34–44, 2015.
- [8] M. Gravel, C. Gagne, and W. L. Price, "Review and comparison of three methods for the solution of the car sequencing problem," *Journal of the Operational Research Society*, vol. 56, no. 11, pp. 1287–1295, 2005.
- [9] M. Fliedner and N. Boysen, "Solving the car sequencing problem via branch & bound," *European Journal of Operational Research*, vol. 191, no. 3, pp. 1023–1042, 2008.
- [10] J. Bautista, J. Pereira, and B. Adenso-Díaz, "A beam search approach for the optimization version of the car sequencing problem," *Annals of Operations Research*, vol. 159, no. 1, pp. 233–244, 2008.
- [11] U. Golle, F. Rothlauf, and N. Boysen, "Iterative beam search for car sequencing," *Annals of Operations Research*, vol. 226, no. 1, pp. 239–254, 2015.
- [12] J. Gottlieb, M. Puchta, and C. Solnon, "A study of greedy, local search, and ant colony optimization approaches for car sequencing problems," in *Applications of evolutionary computing*. Springer, 2003, pp. 246–257.
- [13] S. Morin, C. Gagné, and M. Gravel, "Ant colony optimization with a specialized pheromone trail for the car-sequencing problem," *European Journal of Operational Research*, vol. 197, no. 3, pp. 1185–1191, 2009.
- [14] A. Zinflou, C. Gagné, and M. Gravel, "Crossover operators for the car sequencing problem," in *Evolutionary Computation in Combinatorial Optimization*. Springer, 2007, pp. 229–239.
- [15] —, "Genetic algorithm with hybrid integer linear programming crossover operators for the car-sequencing problem," *INFOR: Information Systems and Operational Research*, vol. 48, no. 1, pp. 23–37, 2010.
- [16] I. P. Gent and T. Walsh, "CSPLib: a benchmark library for constraints," in *Principles and Practice of Constraint Programming—CP'99*. Springer, 1999, pp. 480–481.
- [17] M. Puchta and J. Gottlieb, "Solving car sequencing problems by local optimization," in *Applications of Evolutionary Computing*. Springer, 2002, pp. 132–142.
- [18] B. Estellon, F. Gardi, and K. Nouioua, "Two local search approaches for solving real-life car sequencing problems," *European Journal of Operational Research*, vol. 191, no. 3, pp. 928–944, 2008.
- [19] C. Solnon, "Combining two pheromone structures for solving the car sequencing problem with Ant Colony Optimization," *European Journal of Operational Research*, vol. 191, no. 3, pp. 1043–1055, 2008.
- [20] C. Solnon, V. D. Cung, A. Nguyen, and C. Artigues, "The car sequencing problem: Overview of state-of-the-art methods and industrial case-study of the ROADEF'2005 challenge problem," *European Journal of Operational Research*, vol. 191, no. 3, pp. 912–927, 2008.
- [21] M. Prandtstetter and G. R. Raidl, "An integer linear programming approach and a hybrid variable neighborhood search for the car sequencing problem," *European Journal of Operational Research*, vol. 191, no. 3, pp. 1004–1022, 2008.
- [22] E.-G. Talbi, *Metaheuristics: from design to implementation*. John Wiley & Sons, 2009.
- [23] T. A. Feo and M. G. Resende, "Greedy randomized adaptive search procedures," *Journal of global optimization*, vol. 6, no. 2, pp. 109–133, 1995.
- [24] N. Mladenović and P. Hansen, "Variable neighborhood search," *Computers & Operations Research*, vol. 24, no. 11, pp. 1097–1100, 1997.
- [25] A. A. Juan, J. Faulin, S. E. Grasman, M. Rabe, and G. Figueira, "A review of simheuristics: Extending metaheuristics to deal with stochastic combinatorial optimization problems," *Operations Research Perspectives*, vol. 2, pp. 62–72, 2015.
- [26] H. De Beukelaer, G. F. Davenport, G. De Meyer, and V. Fack, "JAMES: An object-oriented Java framework for discrete optimization using local search metaheuristics," *Software: Practice and Experience*, vol. 47, no. 6, pp. 921–938, 2017.
- [27] M. Dorigo and T. Stützle, "Ant colony optimization: overview and recent advances," *Handbook of metaheuristics*, 2010.

# Secuenciación en líneas de fabricación no sincronizadas con ensamblajes

## Modelado matemático y resolución heurística

Carlos Andrés

Departamento de Organización de Empresas  
Universitat Politècnica de València  
Valencia  
candres@omp.upv.es

Julien Maheut

Departamento de Organización de Empresas  
Universitat Politècnica de València  
Valencia  
Juma2@upvnet.upv.es

**Abstract**—En este trabajo se presenta el problema de establecer la secuencia en una línea de montaje no sincronizada en donde cada estación de trabajo se abastece por otra máquina. Entre cada estación de trabajo o máquina existen almacenes de capacidad limitada que pueden provocar bloqueos en las instalaciones precedentes si llegan a saturar su capacidad. Se modela el problema como un taller de flujo con ensamblajes y almacenes intermedios con el objetivo de minimizar  $C_{max}$  y se realiza un estudio sobre el rendimiento de diferentes heurísticas, presentándose una adaptación de la metaheurística VNS al problema.

**Keywords**—líneas de fabricación; taller de flujo; almacén limitado; heurística; Variable Neighbourhood Search

### I. INTRODUCCIÓN

Desde el trabajo seminal de [1] se ha desarrollado una vastísima literatura relativa a la Programación de Producción en sistemas de fabricación y, en concreto, al estudio de modelos y algoritmos para resolver el problema de la secuencia en diferentes configuraciones. Una de las configuraciones más estudiadas es el taller de flujo o “flowshop” en el que todos los trabajos tienen la misma ruta de operaciones en las  $M$  máquinas donde se procesan y el objetivo es determinar el orden de paso de un conjunto de  $N$  trabajos por las máquinas que optimice cierta medida de eficiencia de la secuencia [2].

Dentro del conjunto de soluciones posibles a cualquier instancia de este tipo de problema, muchos trabajos se han centrado en el subconjunto formado por aquellas con la propiedad denominada “de permutación”, esto es, su secuencia de paso es idéntica en todas las máquinas [3], [4]. Esto es debido a que la solución óptima para ciertos casos de optimización es una secuencia de permutación y que, en muchos problemas reales, la disciplina FIFO es la que se aplica con más frecuencia en el transporte de los trabajos entre las máquinas debido a las políticas de transporte de los trabajos entre las máquinas.

Más recientemente, otro tipo de configuración denominada taller con ensamblajes “assembly shop” [5], [6], ha empezado a llamar la atención de los investigadores. En este tipo de problemas se considera que existe al menos una máquina o etapa que funciona como ensambladora de las partes y componentes

producidas por otras máquinas. De esta manera, no es posible empezar una operación de un trabajo en una máquina, si no han llegado a la misma todos los componentes necesarios para ejecutarla. Este tipo de configuraciones posibilita el estudio de muchas más variantes de sistemas productivos industriales que los que se estudian con el taller de flujo puesto que incide en el problema de la coordinación a nivel de programa de producción de la fabricación de los componentes necesarios para obtener un producto concreto.

En la mayoría de la investigación realizada sobre estas configuraciones se asume que existe una capacidad de almacenamiento infinito entre las máquinas del taller. Sin embargo, en los sistemas productivos reales siempre hay una limitación de capacidad debido a la necesidad física que los trabajos esperen antes de ser procesados en una máquina si ésta se encuentra ocupada procesando el trabajo previo de la secuencia. Esta limitación es más relevante cuanto mayor es el volumen o tamaño de las piezas o lotes procesados entre las máquinas. En general, la limitación que se considera en la literatura de secuenciación se establece en base al número máximo de trabajos que pueden almacenarse en cada instante entre dos máquinas (asumiendo de esta manera que todos los trabajos tienen un volumen parecido o se transportan en contenedores estandarizados). Según se recoge en [7] existe un número creciente de trabajos en los que ya se considera explícitamente la limitación de capacidad entre etapas del proceso de fabricación.

Un prometedor campo de investigación es el de la programación de unidades en líneas mixtas de fabricación y/o montaje no sincronizadas con limitación de capacidad. En esta configuración, un trabajo solamente puede ser liberado de una estación de la línea a la siguiente estación si existe capacidad de almacenamiento suficiente entre ambas estaciones. Este tipo de sistemas productivos, se pueden modelar como talleres de flujo con almacenes intermedios según se ha propuesto por [8].

El objetivo de este trabajo es profundizar en este tipo de configuraciones en las que, además de una línea de fabricación y/o montaje principal, existen una serie de líneas o estaciones de abastecimiento conectadas. Un ejemplo real de este tipo de sistemas productivos se muestra en la Fig. 1.

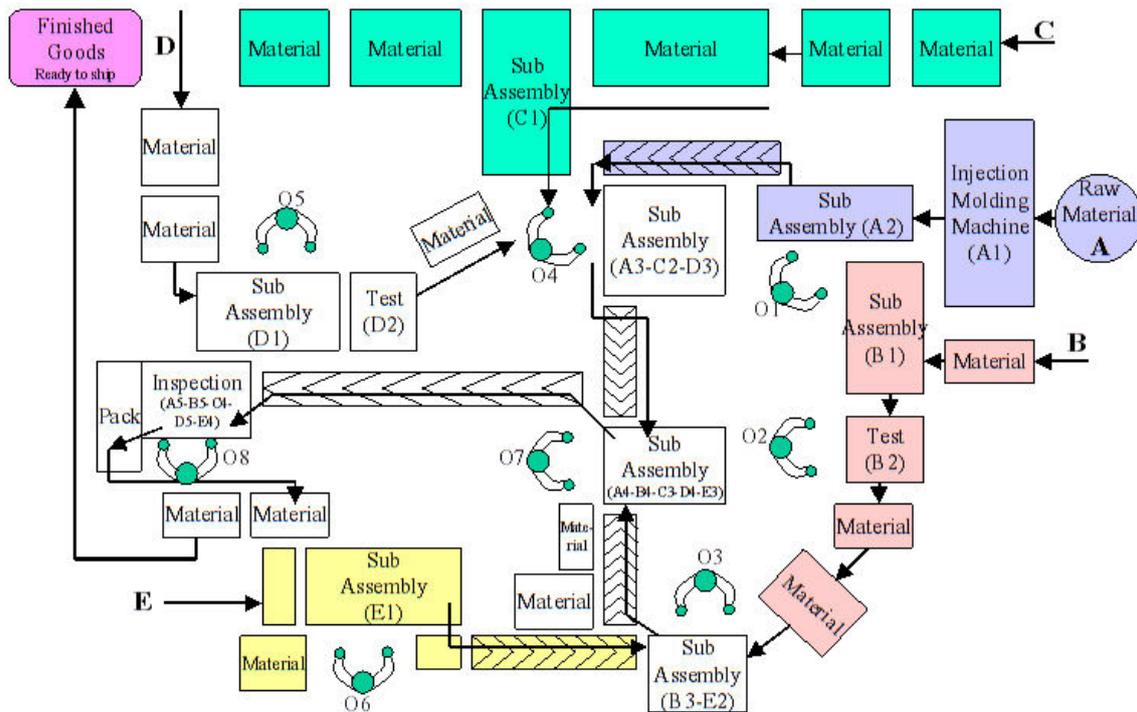


Fig. 1. Ejemplo de sistema productivo real con ensamblajes

II. PLANTEAMIENTO Y MODELADO DEL PROBLEMA

A. Descripción del problema

La configuración objeto de estudio está formada por una línea principal compuesta por M máquinas o estaciones. A cada una de estas máquinas le llegan componentes procedentes de una máquina de fabricación de componentes. Existen almacenes intermedios entre cada máquina o estación, tanto de la línea principal las máquinas de fabricación de componentes. Para poder llevar a cabo la operación correspondiente en cada estación de la línea principal es necesario disponer el producto suministrado por la estación anterior y el componente suministrado por la máquina de fabricación. En este trabajo se va a suponer solamente secuencias basadas en permutaciones, esto es, la secuencia es la misma en todas las estaciones de la línea principal y en cada máquina de fabricación de componentes.

B. Notación matemática

Para identificar los diferentes elementos del problema se usará la siguiente notación basada en la configuración mostrada en la Fig.2:

N trabajos o componentes.

M estaciones en la línea principal.

i es el subíndice asociado a los trabajos o componentes (i=1,...,N)

p es el subíndice asociado a la posición ocupada por cada trabajo (p=1,...,N)

j es el subíndice asociado a las estaciones de trabajo de la línea principal (j=1,...,M)

M<sub>j</sub> identifica cada estación de trabajo de la línea principal (j=1,...,M). Además, se consideran M máquinas de abastecimiento que suministran MxN componentes en total debido a que solo hay una máquina abasteciendo a cada estación de trabajo. Cada una de estas máquinas se denotarán por MC<sub>j</sub> j=1,...,M

pc<sub>ij</sub> es el tiempo de proceso del componente necesario para el producto i en la máquina de abastecimiento MC<sub>j</sub>.

p<sub>i</sub> es el tiempo de proceso del producto i en cada estación M<sub>j</sub> de la línea principal.

Entre cada par de estaciones de trabajo j-1 y j de la línea principal existe un almacén intermedio B<sub>j</sub>. Del mismo modo, entre una estación de trabajo M<sub>j</sub> y una máquina de abastecimiento de componentes MC<sub>j</sub> existe un almacén intermedio BC<sub>j</sub>.

De esta forma se considera que bc<sub>j</sub> es la capacidad de almacenamiento (en unidades) del almacén que existe entre la máquina de abastecimiento MC<sub>j</sub> y la estación de ensamblaje M<sub>j</sub> y que b<sub>j</sub> es la capacidad de almacenamiento (en unidades) del almacén que existe entre las estaciones de ensamblaje M<sub>j-1</sub> y M<sub>j</sub>.

SC<sub>pj</sub> ≥ 0 es la fecha de inicio del componente que ocupa la posición p de la secuencia en cada máquina j de abastecimiento.

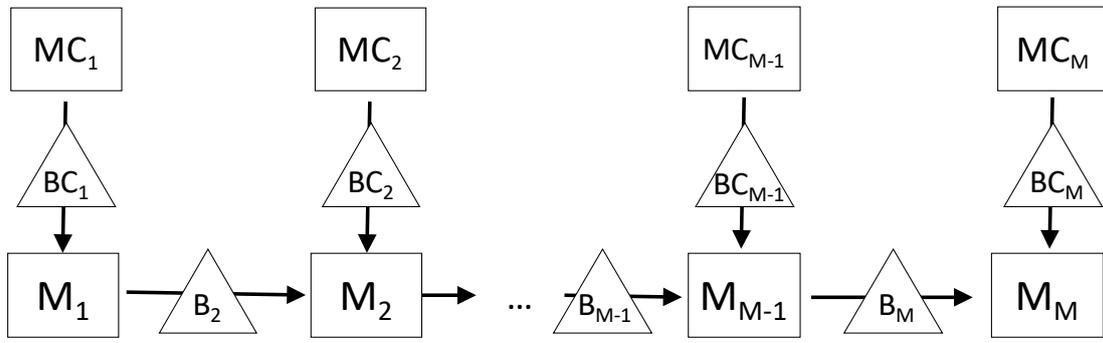


Fig. 2. Configuración estudiada

$S_{p,j} \geq 0$  es la fecha de inicio del producto que ocupa la posición  $p$  de la secuencia en cada estación  $j$  de la línea principal.

$x_{i,p}$  es una variable binaria que vale 1 si el producto  $i$  ocupa la posición  $p$  de la secuencia y 0 en caso contrario.

C. Modelo matemático

El modelo matemático de la configuración estudiada se basa en las definiciones anteriores y es el siguiente:

$$\text{Min } Cmax \tag{1}$$

s.a.

$$\sum_{i=1}^N x_{i,p} = 1 \quad p = 1, \dots, N \tag{2}$$

$$\sum_{p=1}^N x_{i,p} = 1 \quad i = 1, \dots, N \tag{3}$$

$$SC_{1,j} = 0 \quad j = 1, \dots, M \tag{4}$$

$$S_{1,1} \geq SC_{1,1} + \sum_{i=1}^N x_{i,1} \cdot pc_{i,1} \tag{5}$$

$$S_{1,j} \geq SC_{1,j} + \sum_{i=1}^N x_{i,1} \cdot pc_{i,j} \quad j = 2, \dots, M \tag{6}$$

$$S_{1,j} \geq S_{1,j-1} + \sum_{i=1}^N x_{i,1} \cdot p_{i,j-1} \quad j = 2, \dots, M \tag{7}$$

$$SC_{p,j} \geq SC_{p-1,j} + \sum_{i=1}^N x_{i,p-1} \cdot pc_{i,j} \quad \begin{matrix} p = 2, \dots, N; \\ j = 1, \dots, M \end{matrix} \tag{8}$$

$$SC_{p,j} \geq S_{p-bc_j-1,j} \quad \begin{matrix} p > bc_j + 1; \\ j = 1, \dots, M \end{matrix} \tag{9}$$

$$S_{p,1} \geq S_{p-1,1} + \sum_{i=1}^N x_{i,p-1} \cdot p_{i,1} \quad p = 2, \dots, N \tag{10}$$

$$S_{p,1} \geq SC_{p,1} + \sum_{i=1}^N x_{i,p} \cdot pc_{i,1} \quad p = 2, \dots, N \tag{11}$$

$$S_{p,1} \geq S_{p-b_2-1,2} \quad p > b_{j+1} + 1 \tag{12}$$

$$S_{p,j} \geq S_{p-1,j} + \sum_{i=1}^N x_{i,p-1} \cdot p_{i,j} \quad \begin{matrix} p = 2, \dots, N; \\ j = 2, \dots, M - 1 \end{matrix} \tag{13}$$

$$S_{p,j} \geq S_{p,j-1} + \sum_{i=1}^N x_{i,p} \cdot p_{i,j-1} \quad \begin{matrix} p = 2, \dots, N; \\ j = 2, \dots, M - 1 \end{matrix} \tag{14}$$

$$S_{p,j} \geq SC_{p,j} + \sum_{i=1}^N x_{i,p} \cdot pc_{i,j} \quad \begin{matrix} p = 2, \dots, N; \\ j = 2, \dots, M - 1 \end{matrix} \tag{15}$$

$$N \geq p \geq 2 + b_{j+1} + 1; \quad j = 2, \dots, M - 1 \tag{16}$$

$$S_{p,M} \geq S_{p-1,M} + \sum_{i=1}^N x_{i,p-1} \cdot p_{i,M} \quad p = 2, \dots, N \tag{17}$$

$$S_{p,M} \geq S_{p,M-1} + \sum_{i=1}^N x_{i,p} \cdot p_{i,M-1} \quad p = 2, \dots, N \tag{18}$$

$$S_{p,M} \geq SC_{p,M} + \sum_{i=1}^N x_{i,p} \cdot pc_{i,M} \quad p = 2, \dots, N \tag{19}$$

$$Cmax = S_{N,M} + \sum_{i=1}^N x_{i,N} \cdot p_{i,M} \tag{20}$$

La expresión (1) corresponde a la función objetivo a optimizar que en este trabajo es la fecha de fin del último trabajo secuenciado o makespan. (2) y (3) son restricciones de asignación biunívoca que obligan a que en cada posición de la secuencia haya solo un trabajo y que cada trabajo se asigne solamente a una posición. La restricción (4) define que el instante de inicio en las máquinas de abastecimiento del primer componente es cero. (5) indica que el producto en primera posición empieza en la primera estación de la línea cuando acaba la fabricación del componente en la primera máquina de abastecimiento.

Las restricciones (6) y (7) afectan a la fecha de inicio del producto que va en primera posición de la secuencia en todas las estaciones de trabajo en función de la máquina que fabrica su



componente y de la estación anterior de la línea donde se procesa.

Las ecuaciones (8) y (9) permiten calcular las fechas de inicio en las máquinas de abastecimiento de los componentes necesarios para ensamblar el resto de productos de la secuencia. En concreto, (8) se aplica a aquellos productos cuya posición en la secuencia es tal que no se ven afectados por el tamaño de los almacenes que hay entre las máquinas de abastecimiento y las máquinas de ensamblaje. En este caso, las fechas de inicio solo se ven condicionadas por la fecha de fin del componente perteneciente al producto de la posición previa de la secuencia, ya que antes de las máquinas  $MC_j$  no hay otra máquina. Sin embargo, en (9) además de este hecho se debe tener en cuenta que más allá de la posición  $bc_j+1$ , los componentes solo pueden empezar cuando empiecen los que están  $bc_j$  posiciones antes.

Las ecuaciones (10) y (11) son similares a las dos anteriores, pero en este caso, afectan a las fechas de inicio en la primera máquina de la línea principal de los productos que están después de la posición 1. En ellas se tiene en cuenta las fechas de inicio de los trabajos que no se ven afectados por la capacidad del almacén que se encuentra entre las máquinas  $M1$  y  $M2$  de la línea principal (y solo dependen de la fecha de fin en la máquina de abastecimiento del componente necesario para montar el trabajo, y la fecha de fin del trabajo anterior en la  $M1$ ).

En (12) se tiene en cuenta un término adicional que depende de la fecha en la que el trabajo que está en  $b2$  posiciones antes, abandona el almacén  $b2$ .

Las expresiones (13) (14) (15) y (16) se aplican de la segunda máquina de la línea principal de ensamblaje en adelante. Es por ello que incorporan términos adicionales en sus expresiones para identificar las relaciones de las fechas de inicio de los trabajos en la máquina, con las fechas de fin del trabajo en la máquina anterior de la línea principal, las fechas de fin del componente necesario en la máquina de abastecimiento correspondiente, la fecha de fin del trabajo anterior en la máquina, y en el caso de la expresión (16) las relaciones en el almacén de capacidad limitada entre la máquina y la máquina siguiente.

Dado que la última máquina  $M$  de la línea principal no tiene almacén posterior, son necesarias las expresiones (17) (18) y (19) para calcular los tiempos de inicio en esa máquina. Finalmente, (20) permite calcular la fecha de fin del último trabajo de la secuencia.

### III. HEURÍSTICAS Y METAHEURÍSTICA PLANTEADAS

Pese a la existencia del modelo matemático descrito en el apartado anterior, en el apartado siguiente se muestra la dificultad de abordar instancias de tamaño medio o grande. Por ello, se han propuesto varias heurísticas y una metaheurística basada en Búsqueda por Entorno Variable (VNS) para resolver el problema. A continuación, se hace una descripción de las características principales de estos métodos.

#### A. Heurísticas

Se han evaluado tres reglas heurísticas adaptadas al problema que nos ocupa.

#### 1) Heurística NEH

La primera regla que se ha elegido es la conocida como regla NEH [9], puesto que ha dado muy buenos resultados en diversas variantes de flowshop [3]. Específicamente, en [10] se corrobora su bondad para configuraciones flowshop con capacidad de almacenamiento limitada.

En lo que se refiere a su funcionamiento, la regla NEH se basa en la ordenación de los trabajos en función de un criterio determinado (en el artículo original se usa la regla de mayor tiempo de proceso). En el presente trabajo, la regla de ordenación de los trabajos considera tanto los tiempos en las estaciones de ensamblaje como los de las máquinas de fabricación de componentes. Así se han tenido en cuenta los siguientes criterios de ordenación:

- $MAX\_T/MIN\_T$ : Valor máximo (o mínimo) para cada trabajo entre todos los tiempos (tanto de la línea principal como las de las máquinas de fabricación de componentes).
- $SUM\_T$ : Para cada trabajo, la suma de todos los tiempos (tanto de la línea principal como las de las máquinas de fabricación de componentes).
- $MAX\_T\_P/MIN\_T\_P$ : Valor máximo (o mínimo) para cada trabajo entre todos los tiempos de la línea principal.
- $SUM\_T\_P/SUM\_T\_C$ : Para cada trabajo, la suma de todos los tiempos en las estaciones de ensamblaje de fabricación de componentes (o en las máquinas de fabricación de componentes).
- $MAX\_T\_C/MIN\_T\_C$ : Valor máximo (o mínimo) para cada trabajo entre todos los tiempos de proceso en las máquinas de fabricación de componentes.

#### 2) Heurística PF

En [11] se propuso la regla conocida como PF o Profile Fitting dentro de un caso de fabricación cíclica en un flowshop con almacenes (asimilable a una línea no sincronizada de fabricación con mezcla de modelos). Al ser una regla que tiene en cuenta los bloqueos y esperas de las máquinas se ha considerado en este trabajo puesto que se le supone un buen rendimiento en sistemas con ensamblajes donde hay muchas posiciones que originan esperas.

El procedimiento comienza eligiendo como primer trabajo de la secuencia aquel que tiene la mayor suma de tiempos de proceso. En nuestro caso optaremos por elegir el mayor de las sumas de tiempos de proceso en todas las máquinas (tanto de componentes como principales). Una vez elegido el primer trabajo  $i^*$ , se calcula para el resto de trabajos candidatos  $ic$  el valor  $\sum_{j=1}^M D_{[ic]j} - D_{[i^*]j} - p_{[ic]j}$ , donde  $D_{[ij]} = \max(C_{[ij]}, S_{[i-b(j+1)]j+1})$ . El sumatorio se extiende a todas las máquinas (tanto las de la línea principal como las de abastecimiento) y se elige aquel trabajo  $ic$  en el que se obtenga la suma menor. Este trabajo ahora se convierte en  $i^*$  y se repite el proceso hasta que se completa la secuencia.

### 3) Heurística MM

La última regla que se usará en esta comparación es la definida en [12] para configuraciones flowshop con bloqueo. En primer lugar, se elige en primera posición de la secuencia aquel trabajo que tenga menor tiempo de proceso en la primera máquina de la línea principal. A continuación, se coloca en última posición aquel trabajo que tenga el tiempo de proceso menor en la última máquina de la línea principal. A continuación del trabajo en primera posición ( $i^*$ ) se coloca un trabajo ( $i_c$ ) con el menor valor de la siguiente expresión:

$$\alpha \cdot \sum_{j=1}^{M-1} |p_{i_c,j} - p_{i^*,j+1}| - (1 - \alpha) \cdot \sum_{j=1}^M p_{i_c,j} \quad (21)$$

Donde M son las máquinas de la línea principal. Una vez colocado el trabajo elegido, este pasa ahora a ser  $i^*$  y se repite el proceso hasta que no hay más trabajos por colocar. En este trabajo se han propuesto adicionalmente dos variantes, la primera es usar, en vez de los valores de tiempos de proceso en la línea principal, el mayor entre los tiempos de proceso del trabajo  $i$  en la máquina que ensambla componentes para la máquina  $j$  y la máquina  $j$  de la línea principal. La segunda es utilizar la suma de ambos tiempos de procesado en las dos máquinas (la de fabricación de componentes y la de la línea principal).

### B. Búsqueda por entorno variable (VNS)

La metaheurística VNS o búsqueda por entorno variable fue planteada por primera vez en [13] y se trata de un procedimiento de búsqueda local que usa sucesivamente diversos tipos de movimiento (con sus entornos asociados  $N_k$ ) para explorar eficientemente el espacio de soluciones. La estrategia de búsqueda se basa en realizar cambios sistemáticos de entorno dentro de la búsqueda local y aumentar el tamaño del entorno cuando la búsqueda no avanza mediante una gran perturbación denominada “agitación”. Pueden plantearse diversos tipos de movimientos de agitación del mismo modo que se manejan diferentes entornos para la búsqueda local [14].

Como elemento novedoso, en este trabajo planteamos una variante de VNS a la que se añade un mecanismo de reinicio basado en frecuencias. Inicialmente se parte de una solución inicial obtenida mediante la regla NEH, sin embargo, en el momento en que se han realizado todos los movimientos según las diferentes combinaciones de movimientos de agitación y búsqueda local, se reinicia una nueva solución mediante un procedimiento constructivo. Este procedimiento genera una secuencia basada en las posiciones relativas de los trabajos que se obtienen en aquellas soluciones que, en una iteración determinada, han mejorado la mejor solución encontrada.

En este trabajo, y usando una representación del problema basada en una permutación de los trabajos, se han utilizado los siguientes movimientos de agitación: realizar varias inserciones, realizar varios swaps entre dos posiciones aleatoriamente elegidas, elegir varios trabajos en posiciones consecutivas y reescribirlos en orden inverso, y elegir varios trabajos en posiciones no consecutivas y reescribirlos en orden inverso.

En cuanto a los movimientos de búsqueda local, se han usado: inserción de un trabajo entre otros, intercambio de posiciones de dos trabajos consecutivos e intercambio de posiciones de dos trabajos no consecutivos.

El criterio de parada se ha fijado en un número de iteraciones determinado, aunque se ha monitorizado el tiempo de cálculo de cara al estudio experimental que se detalla en el siguiente apartado.

## IV. ESTUDIO EXPERIMENTAL

El estudio experimental se ha desarrollado sobre tres grupos de instancias: pequeñas, medianas y grandes. Todas ellas se han generado a partir del conocido conjunto de instancias de [15] adaptándolas para el caso que nos ocupa.

Con las instancias pequeñas (9 trabajos y cinco estaciones de trabajo) se ha realizado una enumeración completa de todas las soluciones y se han representado en la Fig. 4 para poder tener una visión del aspecto que puede tener el espacio de soluciones.

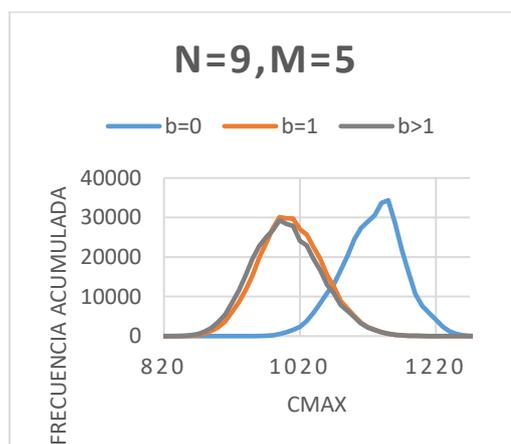


Fig. 3. Estudio de enumeración completa

Se ha observado experimentalmente una clara diferencia cuando el tamaño de los almacenes es nulo respecto a lo que sucede para tamaños de almacenes mayores. Siendo inexistente la influencia que tiene el tamaño de los almacenes intermedios para valores superiores a 1.

En el caso de las instancias medianas (instancias de 20 y 50 trabajos, y 5 y 10 estaciones de trabajo) se ha realizado un estudio experimental para evaluar hasta qué tamaño es posible resolver de manera óptima el problema. En la Tabla 1 se muestra el resultado de resolver 80 instancias diferentes con tamaños de almacén de 0 a 3.

Según la tabla, se puede concluir que el tamaño de los almacenes influye sobre la posibilidad de resolver óptimamente una instancia. Del mismo modo, el número de trabajos a secuenciar y el de máquinas también tienen influencia, siendo el primero más influyente que el segundo, puesto que, al aumentar el número de trabajo, provoca que, para un gran número de instancias, no se puedan ni siquiera calcular una relajación del modelo que permita la aplicación de las técnicas de ramificación implementadas en el optimizador

TABLA 1.



N	M	b	% Resuelto óptimamente	%GAP <0,05	0,05<%GAP <0,3	No solución
20	5	0	0%	20%	80%	0%
		1	20%	80%	0%	0%
		2	100%	0%	0%	0%
		3	80%	20%	0%	0%
	10	0	0%	100%	0%	0%
		1	0%	20%	80%	0%
		2	0%	60%	40%	0%
		3	0%	60%	40%	0%
		3	0%	60%	40%	0%
50	5	0	0%	0%	40%	60%
		1	0%	0%	20	80%
		2	0%	20%	80%	0%
		3	20%	60%	0%	20%
	10	0	0%	0%	80%	10%
		1	0%	0%	40%	60%
		2	0%	0%	40%	60%
		3	0%	0%	60%	40%
		3	0%	0%	60%	40%

Finalmente, se ha usado un conjunto de instancias grandes (200 y 500 trabajos, 5, 10 y 20 estaciones de trabajo y tamaños de almacén de 0 a 4) para evaluar el rendimiento de las heurísticas y la metaheurística VNS descrita. Se ha realizado un estudio de ajuste de parámetros en aquellas heurísticas que lo requieren de cara a definir el mejor criterio de ordenación en el caso de la regla NEH o el valor de  $\alpha$  más adecuado en el caso de la regla MM. En la Fig. 4 se puede observar el gráfico de medias de las reglas (donde 1 es la regla MM, 2 la PF y 3 la NEH) en el que se observa la clara superioridad de la regla NEH.

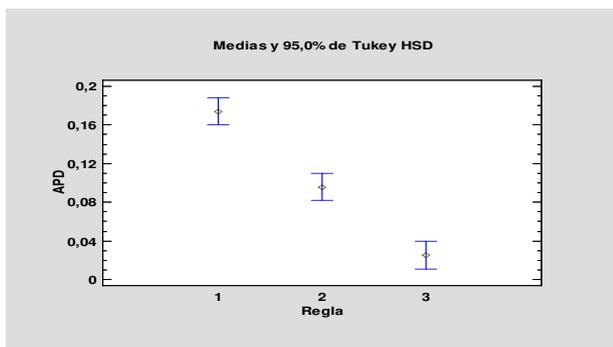


Fig. 4. Gráfico de medias

En el caso de VNS, su comportamiento es superior a la regla NEH, puesto que permite mejorar sus resultados en el 97,91% de las experiencias planteadas. En concreto, comparando las mismas instancias con diferentes tamaños de almacén, se ha observado que, el % en que VNS mejora a NEH aumenta según aumenta el tamaño de almacén (de una mejora del 0,52% respecto a la solución obtenida mediante NEH para los problemas con tamaño de almacén igual a cero hasta un 6,3% para problemas con tamaño de almacén igual a 4). Esto, indica que VNS es más efectiva respecto a NEH cuanto mayor es la capacidad de los almacenes intermedios.

Además, y basándonos ya en los resultados obtenidos por VNS, el estudio muestra que la influencia del tamaño del

almacén decrece conforme aumenta el tamaño de almacén, siendo casi despreciable a partir de tamaños superiores a 4.

## V. CONCLUSIONES

En este trabajo se ha abordado el estudio de una configuración tipo flowshop con máquinas auxiliares de abastecimiento que presenta limitación de capacidad entre las diferentes máquinas del sistema. Este tipo de configuraciones son de gran interés porque permite representar tanto líneas de fabricación no sincronizadas como otros sistemas complejos en los que existen máquinas destinadas a la fabricación de componentes. Se ha propuesto un modelo matemático que permite obtener soluciones óptimas para instancias de hasta 20 trabajos. Además, se ha observado que los tamaños de los almacenes intermedios influyen sobre el problema, tanto en la topología del espacio de soluciones como en la capacidad de alcanzar buenas soluciones (o incluso óptimas) en un tiempo limitado.

## REFERENCIAS

- [1] S.M. Johnson, "Optimal Two- and Three-Stage Production Schedules with Setup Times Included". *Naval Research Logistics Quarterly*, vol. 1, pp. 61-68, 1954
- [2] T. C. E. Cheng, J. Gupta y G. Wang, "A review of flowshop scheduling research with setup times". *Production and operations management*, vol. 9, pp. 262-282, 2000.
- [3] R. Ruiz y C. Maroto, "A comprehensive review and evaluation of permutation flowshop heuristics". *European Journal of Operational Research*, vol. 165, pp. 479-494, 2005
- [4] Q. Pan y R. Ruiz, "A comprehensive review and evaluation of permutation flowshop heuristics to minimize flowtime". *Computers & Operations Research*, vol. 40, pp. 117-128, 2013.
- [5] C. Y. Lee, T.C.E. Cheng y B.M.T. Lin, "Minimizing the makespan in the 3-machine assembly-type flowshop scheduling problem". *Management Science*, vol. 39, pp. 616-625, 1993
- [6] C. N. Potts, S. V. Sevast'janov, V.A. Strusevich, L. N. Van Wassenhove, y C. M. Zwaneveld, "The Two-Stage Assembly Scheduling Problem: Complexity and Approximation". *Operations Research*, vol 43, pp. 346-355, 1995.
- [7] C. Andrés y J. Maheut, "Secuenciación con almacenes limitados. Una revisión de la literatura". *Dirección y Organización*, vol. 66, 2018.
- [8] J. Bautista-Valhondo y R. Alfaro-Pozo, "Mixed integer linear programming models for Flow Shop Scheduling with a demand plan of job types". *Central European Journal of Operations Research*, 2018. <https://doi.org/10.1007/s10100-018-0553-8>
- [9] M. Nawaz, E. E. Enscore e I. Ham, "A heuristic algorithm for the m-machine, n-job flowshop problem". *Omega*, vol. 11, pp.91-95, 1983.
- [10] R. Leisten, "Flowshop sequencing problems with limited buffer storage". *Int. Journal of Prod. Research*, vol. 28, pp. 2085-2100, 1990.
- [11] S. T. McCormick, M. I. Pinedo, S. Shenker, y B. Wolf, "Sequencing in an assembly line with blocking to minimize cycle time". *Operations Research*, vol. 37, pp. 925-936, 1989.
- [12] D. Ronconi, "A note on constructive heuristics for the flowshop problem with blocking". *Int. Journal of Prod. Economics*, vol. 87, pp. 39-48, 2004
- [13] N. Mladenović, P. Hansen, "Variable neighborhood search". *Computers & Operations Research*, vol. 24, pp. 1097-1100, 1997.
- [14] J. A. M. Pérez, N. Mladenović, B. M. Batista e I. J. G del Amo, "Variable Neighbourhood Search", in *Metaheuristic Procedures for Training Neural Networks*. *Op. Res. /Comp. Sc. Interfaces Series*, vol 36. E. Alba y R. Martí, Eds, Boston: Springer, 2006
- [15] E. Taillard, "Benchmarks for basic scheduling problems". *European Journal of Operational Research*, vol. 64, pp. 278-285, 1993.

# Equilibrado robusto de una línea de motores mixtos con atributos temporales, espaciales y ergonómicos

Joaquín Bautista<sup>1</sup>, Manuel Chica<sup>2</sup>, Oscar Cordon<sup>2</sup>, Sergio Damas<sup>2</sup>

<sup>1</sup>IOC-ETSEIB-Nissan Chair, Universidad Politécnica de Catalunya, España

<sup>2</sup>Instituto Andaluz Interuniversitario DaSCI (Data Science and Computational Intelligence), Universidad de Granada, España  
Emails: joaquin.bautista@upc.edu, manuelchica@ugr.es, ocordova@decsai.ugr.es, sdamas@ugr.es

**Resumen**— Partiendo de los modelos TSALBP-ergo (*Time and Space Assembly Line Balancing Problem with Ergonomic Risk*), proponemos 9 métricas para medir la robustez de un equilibrado de línea según sus atributos temporales, espaciales y contingentes. La versión robusta de TSALBP-ergo considera diversos planes de demanda e incluye funciones que miden los excesos de cargas temporales, espaciales y de riesgo ergonómico en las estaciones de la línea de montaje. Las métricas propuestas son útiles como funciones objetivo en problemas de optimización o se pueden emplear como indicadores del nivel de robustez de una línea. La nueva versión r-TSALBP-ergo pone a disposición del decisor nuevas soluciones de equilibrado más eficientes y robustas ante una demanda incierta.

**Keywords**—Líneas de ensamblado; Demanda incierta; Riesgo Ergonómico; Optimización robusta.

## I. INTRODUCCIÓN

El diseño de una línea de montaje presenta tres vertientes como mínimo: (i) establecer el número de estaciones y decidir qué operaciones se realizarán en cada puesto de trabajo en función de la demanda, (ii) ofrecer una distribución en planta que contemple tanto el espacio requerido por el producto y sus componentes como los espacios adicionales para el desempeño correcto del trabajo de los operarios, y (iii) evitar que el reparto de cargas de trabajo entre estaciones genere lesiones físicas a los trabajadores a medio-largo plazo.

Dentro del sector de Automoción de los países de la OCDE, las líneas de montaje de modelos mixtos están capacitadas para ensamblar distintos tipos de producto, como es el caso de las plantas de motores que usan la misma instalación para fabricar distintas versiones de motores para vehículos SUVs, furgonetas y camiones.

El ensamblado de estos tipos de producto está constituido por tareas semejantes que presentan características comunes; no obstante, cada tipo de producto requiere piezas específicas, distintas formas de aplicar el trabajo, distintas herramientas y distintas habilidades y esfuerzo de los operarios. Obviamente, esta distinción se da tanto entre tipos de producto de la misma familia (v.g.- dos versiones de la familia SUVs) como entre productos de distintas familias (v.g. SUVs o camiones). En estos casos, el ensamblado de un motor requiere unas 400 tareas que pueden agregarse en unas 150 operaciones básicas ya sea por conveniencia o condicionantes de tipo tecnológico.

Brevemente, una línea de montaje es un sistema productivo constituido por un conjunto de estaciones de trabajo a las que se asigna de manera exclusiva una serie de tareas. Cada tarea requiere un tiempo de proceso (función de la actividad de los

operarios), un esfuerzo físico (según la categoría del riesgo ergonómico), y un espacio para el producto y sus componentes, la instrumentación y los recursos humanos. La definición de las tareas es el resultado de concebir la fabricación de un producto complejo como la superposición de las mismas, dando lugar a un problema denominado equilibrado de líneas de montaje (ALB: Assembly Line Balancing) [1], [2]. Las soluciones se basan en distribuir eficientemente las tareas entre estaciones, cumpliendo un conjunto de restricciones.

El problema de equilibrado de líneas en su versión simple denominado SALBP [3] (Simple Assembly Line Balancing Problem), consiste en repartir óptimamente las tareas entre las estaciones, respetando las restricciones de precedencia entre ellas, siguiendo dos criterios de optimización: (i) minimizar el número de estaciones de trabajo, dado un tiempo de ciclo de fabricación (SALBP-1), y (ii) maximizar la tasa de producción de la línea, dado un número fijo de estaciones de trabajo (SALBP-2).

TSALBP [4] (Time and Space Assembly Line Balancing Problem) es una extensión natural de SALBP más próxima a situaciones industriales realistas. En efecto, TSALBP incorpora adicionalmente atributos espaciales relacionados tanto con el espacio disponible para distribuir en planta las estaciones de trabajo como con el espacio requerido para ejecutar las tareas y para albergar los componentes de montaje del producto. TSALBP presenta 8 variantes que resultan de considerar las combinaciones de 3 criterios de optimización:  $m$  (número de estaciones),  $c$  (tiempo de ciclo) y  $A$  (área lineal disponible de las estaciones).

Por su parte, TSALBP-ergo [5] (Time and Space Assembly Line Balancing Problem with Ergonomic Risk) es una familia de problemas que incorpora a TSALBP el concepto de Riesgo Ergonómico tanto en la función objetivo como en restricciones adicionales en las estaciones de trabajo de la línea de montaje. Obviamente, TSALBP-ergo presenta 16 variantes al considerar las combinaciones de 4 criterios de optimización: los 3 criterios de TSALBP más  $R$  (riesgo ergonómico).

En este contexto, la flexibilidad en la fabricación es una propiedad importante de cara a que las grandes compañías puedan responder a cambios de su entorno económico. Entre dichos cambios está el de la variación de la demanda de sus productos. Esta variación puede ser tanto global, afectando al tiempo de ciclo de la línea, como parcial, afectando al mix de producción y a los atributos de las tareas (tiempos de proceso, áreas requeridas y riesgos ergonómicos).

La variación del mix de producción, representada a través de planes de producción diarios, obliga a reequilibrar la línea.



Esta alteración conduce normalmente a la reconfiguración de algunos o todos los puestos de trabajo, llegando a veces a ser necesaria nueva obra civil.

Para evitar cambios notables en la distribución en planta de la línea, se puede recurrir a la implantación de soluciones que sean lo más robustas posibles ante la variación de la demanda [6]-[8].

En este trabajo proponemos métricas para TSALBP-ergo, como extensión a [7], que permiten incorporar a los modelos el concepto de solución robusta [9] mediante restricciones y funciones objetivo. Para ello, las restricciones y las funciones objetivo contienen toda la información de un conjunto de referencia de planes de demanda (también llamados escenarios) que alteran los valores de los atributos temporales, espaciales y de contingencia de las tareas. Esto nos conduce a la definición de funciones de robustez temporal, espacial y de riesgo que miden las sobrecargas de tiempo, espacio y riesgo ergonómico en las estaciones, así como el grado de factibilidad del conjunto de planes de demanda.

El resto del texto sigue la siguiente estructura. La Sección II describe sucintamente la robustez en problemas ALB. En la Sección III describimos las condiciones de TSALBP-ergo ante una demanda incierta. En la Sección IV formalizamos y modelamos el problema objeto de estudio. En la Sección V presentamos algunos ejemplos ilustrativos. Por último, en la Sección VI recogemos nuestras conclusiones.

## II. ROBUSTEZ EN LOS PROBLEMAS DE EQUILIBRADO DE LÍNEAS

Una forma de hallar soluciones robustas en ALBP consiste en buscar configuraciones que se ajusten a todos los escenarios posibles o, en su defecto, que ofrezcan un desempeño eficiente en todos ellos [10], [7], [11]. En [12] se presenta un modelo robusto para ALB y un programa dinámico que minimiza el tiempo de ciclo de la línea considerando el peor escenario entre los posibles. En [13], se consideran diversos escenarios que caracterizan la demanda inestable en una línea de modelos mixtos.

Otra forma de considerar la incertidumbre y la robustez en ALB es suponer que los tiempos de proceso de las tareas no son deterministas sino que están contenidos en intervalos de valores y se obtienen a partir de una función de distribución conocida. En esta vía se encuentra el trabajo [14], enfocado al SALBP-E, en el que se acotan los tiempos de proceso por intervalos y se busca un compromiso entre la minimización de la función objetivo y los valores de un ratio de estabilidad. En [15] se presentan dos modelos robustos de ALB que consideran la incertidumbre con intervalos de valores de los tiempos de proceso de las operaciones.

## III. TSALBP-ERGO SUJETO A UNA DEMANDA INCIERTA

En nuestro ideario, las tareas en TSALBP-ergo poseen una serie de atributos elementales. Dichos atributos, por su distinta naturaleza, los agrupamos aquí en 3 categorías o clases: (i) temporales, (ii) espaciales y (iii) contingentes. Estos atributos elementales están vinculados a cada operación básica de forma individual.

Son atributos temporales de una tarea: el tiempo de proceso medido a actividad normal y el factor de actividad que se establece para equilibrar la línea. Por su parte, son atributos espaciales de una tarea: el área requerida por los operarios para

ejecutar cómodamente la operación, las dimensiones de los contenedores de piezas relacionadas con la operación, así como el espacio ocupado por herramientas y robots para llevar a cabo el montaje. Finalmente, son atributos contingentes de una tarea: el factor y la categoría de riesgo que supone al operario realizar una tarea, y el tiempo de exposición del operario a dicha tarea.

Cuando la línea fabrica un único tipo de producto, los datos que precisamos para resolver un problema de equilibrado son:

1. El conjunto de operaciones ( $J: j = 1, \dots, |J|$ ) con sus atributos elementales: tiempo de proceso  $t_j: j \in J$ , área lineal requerida  $a_j: j \in J$ , categoría de riesgo  $\chi_j: j \in J$ , y riesgo ergonómico  $R_j: j \in J$ .
2. El conjunto de estaciones de trabajo ( $K: k = 1, \dots, |K|$ )
3. Las restricciones de precedencia, incompatibilidad entre tareas y las restricciones que afectan a los atributos de la línea: número de estaciones ( $m$ ), tiempo de ciclo ( $c$ ), área disponible en cada estación ( $A$ ) y riesgo ergonómico permisible ( $R$ ).

Cuando la línea es de modelos mixtos, los atributos elementales dependen de las tareas y productos, por tanto, teniendo en cuenta el conjunto de tipos de producto ( $I: i = 1, \dots, |I|$ ), los atributos temporales, espaciales y contingentes adoptan respectivamente las formas siguientes:  $t_{ji}, a_{ji}, R_{ji}: j \in J \wedge i \in I$ .

Para simplificar, aquí supondremos  $R_{ji} = \chi_j t_{ji}$  ( $j \in J \wedge i \in I$ ), es decir: el riesgo  $R_{ji}$  depende del tiempo de proceso  $t_{ji}$  y de la categoría de riesgo  $\chi_j$  de la tarea  $j \in J$  (considerando solo un factor de riesgo del conjunto de factores  $\Phi$  ( $\varphi = 1, \dots, |\Phi|$ ))

Lógicamente, una línea de modelos mixtos debe atender a diversos planes de demanda de productos que simbolizamos mediante el conjunto de escenarios  $E$ . No obstante, es común realizar el equilibrado de la línea en función de un plan de demanda  $\varepsilon \in E$ , que definimos mediante el vector de demanda  $\vec{d}_\varepsilon = (d_{1\varepsilon}, \dots, d_{|I|\varepsilon})$  o a través del vector mix de producción  $\vec{\lambda}_\varepsilon = (\lambda_{1\varepsilon}, \dots, \lambda_{|I|\varepsilon})$  - donde  $d_{i\varepsilon}$  es el número de unidades del tipo de producto  $i \in I$  contenidas en el plan de demanda  $\varepsilon \in E$ , y  $\lambda_{i\varepsilon}$  es la proporción del modelo  $i \in I$  en el plan  $\varepsilon \in E$ . Aquí se cumple:  $\vec{\lambda}_\varepsilon = \vec{d}_\varepsilon / D_\varepsilon$  con  $D_\varepsilon = \sum_{i \in I} d_{i\varepsilon}$ .

Normalmente, el equilibrado de la línea se efectúa con los valores promediados de los atributos de las tareas en función de un mix de producción. Por tanto, dado un mix de producción  $\vec{\lambda}_\varepsilon$  ( $\varepsilon \in E$ ), los tiempos de proceso, las áreas lineales y los riesgos ergonómicos de las tareas se determinan como en (1), (2) y (3), respectivamente:

$$\bar{t}_{j\varepsilon} = \sum_{i=1}^{|I|} t_{ji} \lambda_{i\varepsilon}, \forall j \in J \wedge \forall \varepsilon \in E \quad (1)$$

$$\bar{a}_{j\varepsilon} = \sum_{i=1}^{|I|} a_{ji} \lambda_{i\varepsilon}, \forall j \in J \wedge \forall \varepsilon \in E \quad (2)$$

$$\bar{R}_{j\varepsilon} = \sum_{i=1}^{|I|} R_{ji} \lambda_{i\varepsilon}, \forall j \in J \wedge \forall \varepsilon \in E \quad (3)$$

Así, dado un mix de producción de referencia  $\vec{\lambda}_{\varepsilon_0}$  ( $\varepsilon_0 \in E$ ), se dice que la línea de modelos mixtos está equilibrada cuando todas las tareas del conjunto  $J$  han sido repartidas coherentemente entre las estaciones de trabajo del conjunto  $K$ . Esto supone que a todo puesto de trabajo  $k \in K$  se asigna en

exclusiva un grupo de tareas que se denomina carga de trabajo  $S_k$ , respetando, en el reparto, todas las restricciones que afectan a las estaciones. Por tanto, se cumple:

$$\bigcup_{k \in K} S_k = J \wedge (S_k \cap S_{k'} = \emptyset, \forall k \neq k') \quad (4)$$

$$\sum_{j \in S_k} \bar{t}_{j\epsilon_0} \leq c, \forall k \in K \quad (5)$$

$$\sum_{j \in S_k} \bar{a}_{j\epsilon_0} \leq A, \forall k \in K \quad (6)$$

$$\sum_{j \in S_k} \bar{R}_{j\epsilon_0} \leq R, \forall k \in K \quad (7)$$

La condición (4) representa la partición completa del conjunto de tareas  $J$  entre las estaciones del conjunto  $K$ , y las restricciones (5), (6) y (7) corresponden respectivamente a los límites que establecen el tiempo de ciclo  $c$ , el área lineal disponible  $A$  y el riesgo ergonómico permisible  $R$ , sobre los valores de los atributos que resultan tras la asignación de tareas a las estaciones de trabajo ( $\forall k \in K$ ).

#### IV. INCORPORANDO ROBUSTEZ AL TSALBP-ERGO

Llamamos r-TSALB-ergo a la versión robusta de TSALB-ergo. Aquí estableceremos las restricciones del nuevo modelo para un número fijo de estaciones de trabajo, y propondremos un conjunto de métricas para la robustez de configuraciones de líneas de montaje (soluciones:  $\zeta$ ) en r-TSALB-ergo, frente al conjunto de planes de demanda (E).

##### A. Parámetros y variables

- $I$  Conjunto de tipos de producto ( $I: i = 1, \dots, |I|$ )
- $J, P_j$  Conjunto de tareas ( $J: j = 1, \dots, |J|$ ) y Conjunto de tareas precedentes a la tarea  $j \in J$  ( $P_j \subseteq J$ )
- $K$  Conjunto de estaciones de trabajo ( $K: k = 1, \dots, m$ )
- $E$  Conjunto de planes de demanda ( $\epsilon \in E$ )
- $c, \gamma_c, \Delta_c$  Tiempo de ciclo, flexibilidad temporal y tiempo de proceso adicional en toda estación  $k \in K$ . Se define ventana temporal así:  $c + \Delta_c = (1 + \gamma_c)c$
- $A, \gamma_A, \Delta_A$  Área lineal disponible, flexibilidad espacial y área lineal adicional en toda estación  $k \in K$ . Se define ventana espacial así:  $A + \Delta_A = (1 + \gamma_A)A$
- $R, \gamma_R, \Delta_R$  Riesgo ergonómico admisible en toda estación  $k \in K$ , flexibilidad contingente y riesgo adicional en cada estación. Se define ventana de contingencia o de riesgo así:  $R + \Delta_R = (1 + \gamma_R)R$
- $\bar{t}_{j\epsilon}$  Tiempo de proceso promedio de la tarea  $j \in J$  en función del mix de productos en el plan de demanda  $\epsilon \in E$  – ecuación (1) -
- $\bar{a}_{j\epsilon}$  Área lineal promedio requerida por la tarea  $j \in J$  en función del mix de productos en el plan de demanda  $\epsilon \in E$  – ecuación (2) -
- $\chi_j, \bar{R}_{j\epsilon}$  Categoría de riesgo y riesgo ergonómico promedio asociado a la tarea  $j \in J$  en función del mix de productos en el plan de demanda  $\epsilon \in E$  – ecuación (3) – Supondremos  $\bar{R}_{j\epsilon} = \chi_j \bar{t}_{j\epsilon} \quad \forall j \in J \wedge \forall \epsilon \in E$

- $x_{jk}$  Variable binaria que vale 1 si la tarea  $j \in J$  se asigna a la estación  $k \in K$ , y vale 0 en caso contrario.
- $y_{k\epsilon}^c$  Variable binaria que vale 1 si el tiempo de la carga de la estación  $k \in K$ , correspondiente al plan de demanda  $\epsilon \in E$  y a la configuración de referencia  $\zeta_0$  de la línea, es mayor que el tiempo de ciclo – i.e.  $t_\epsilon(S_k) > c$  – y vale 0 en caso contrario.
- $y_{k\epsilon}^A$  Variable binaria que vale 1 si el área lineal de la carga de la estación  $k \in K$ , para el plan de demanda  $\epsilon \in E$  y la configuración de referencia  $\zeta_0$  de la línea, es mayor que el área lineal disponible – i.e.  $a_\epsilon(S_k) > A$  – y vale 0 en caso contrario.
- $y_{k\epsilon}^R$  Variable binaria que vale 1 si el riesgo ergonómico de la carga de la estación  $k \in K$ , para el plan de demanda  $\epsilon \in E$  y la configuración  $\zeta_0$  de la línea, es mayor que el riesgo ergonómico permisible – i.e.  $R_\epsilon(S_k) > R$  – y vale 0 en caso contrario.
- $Y^c$  Variable entera que representa el número de veces que  $t_\epsilon(S_k) > c$  ( $\forall \epsilon \in E, \forall k \in K$ ):  $Y^c = \sum_{\forall \epsilon \forall k} y_{k\epsilon}^c$
- $Y^A$  Variable entera que representa el número de veces que  $a_\epsilon(S_k) > A$  ( $\forall \epsilon \in E, \forall k \in K$ ):  $Y^A = \sum_{\forall \epsilon \forall k} y_{k\epsilon}^A$
- $Y^R$  Variable entera que representa el número de veces que  $R_\epsilon(S_k) > R$  ( $\forall \epsilon \in E, \forall k \in K$ ):  $Y^R = \sum_{\forall \epsilon \forall k} y_{k\epsilon}^R$

##### B. Restricciones para el modelo r-TSALBP-ergo con número fijo de estaciones de trabajo

$$x_{jk} \in \{0,1\}, (\forall j \in J, k \in K) \quad (8)$$

$$y_{k\epsilon}^c \in \{0,1\}, (\forall k \in K, \epsilon \in E) \quad (9)$$

$$y_{k\epsilon}^A \in \{0,1\}, (\forall k \in K, \epsilon \in E) \quad (10)$$

$$y_{k\epsilon}^R \in \{0,1\}, (\forall k \in K, \epsilon \in E) \quad (11)$$

$$\sum_{k \in K} x_{jk} = 1, (\forall j \in J) \quad (12)$$

$$\sum_{j \in J} x_{jk} \geq 1, (\forall k \in K) \quad (13)$$

$$\sum_{k \in K} k(x_{ik} - x_{jk}) \leq 0, (\forall i \in P_j \subseteq J) \quad (14)$$

$$\sum_{j \in J} \bar{t}_{j\epsilon} x_{jk} \leq (c + \Delta_c y_{k\epsilon}^c), (\forall k \in K, \epsilon \in E) \quad (15)$$

$$\sum_{j \in J} \bar{a}_{j\epsilon} x_{jk} \leq (A + \Delta_A y_{k\epsilon}^A), (\forall k \in K, \epsilon \in E) \quad (16)$$

$$\sum_{j \in J} \bar{R}_{j\epsilon} x_{jk} \leq (R + \Delta_R y_{k\epsilon}^R), (\forall k \in K, \epsilon \in E) \quad (17)$$

Las condiciones (8)-(11) permiten forzar la integridad de las variables de decisión del modelo. Las igualdades (12) sirven para asignar cada tarea a una y solo una estación de trabajo. Las restricciones (13) obligan a que toda estación tenga al menos una tarea asignada. Las restricciones (14) aseguran la satisfacción de las precedencias entre tareas. Finalmente, las restricciones (15)-(17) limitan respectivamente el valor de los atributos temporales, espaciales y contingentes, en cada estación y en cada plan de demanda.



### C. Métricas para la robustez en TSALBP-ergo

(mr.1) Proporción de planes del conjunto E satisfechos por la solución  $\zeta_0$ , según la limitación del tiempo de ciclo c.

$$r_c^1 = 1 - \frac{1}{|E|} \sum_{\varepsilon=1}^{|\varepsilon|} \max_{k \in K} y_{k\varepsilon}^c \quad (18)$$

(mr.2) Proporción de estaciones sin sobrecarga de trabajo. Es decir, proporción de estaciones de la línea con tiempo de carga menor o igual que el tiempo de ciclo c.

$$r_c^2 = 1 - \frac{1}{m} \sum_{k=1}^{|K|} \max_{\varepsilon \in E} y_{k\varepsilon}^c \quad (19)$$

(mr.3) Proporción del tiempo de proceso adicional concedido ( $\Delta_c$ ) que no emplea la solución  $\zeta_0$ , Es igual a 1 cuando  $r_c^1 = 1$  o  $r_c^2 = 1$ .

$$r_c^3 = 1 - \frac{1}{\Delta_c Y^c} \sum_{\forall \varepsilon, k} \max \left\{ 0, \sum_{\forall j} \bar{t}_{j\varepsilon} x_{jk} - c \right\} : Y^c > 0, \quad (20)$$

si  $Y^c = 0 \Rightarrow r_c^3 = 1$

(mr.4) Proporción de planes del conjunto E satisfechos por la solución  $\zeta_0$ , según el área lineal disponible A.

$$r_A^1 = 1 - \frac{1}{|E|} \sum_{\varepsilon=1}^{|\varepsilon|} \max_{k \in K} y_{k\varepsilon}^A \quad (21)$$

(mr.5) Proporción de estaciones que requieren un área lineal menor o igual que el área lineal disponible A.

$$r_A^2 = 1 - \frac{1}{m} \sum_{k=1}^{|K|} \max_{\varepsilon \in E} y_{k\varepsilon}^A \quad (22)$$

(mr.6) Proporción del área lineal adicional concedida ( $\Delta_A$ ) que no emplea la solución  $\zeta_0$ . Es igual a 1 cuando  $r_A^1 = 1$  o  $r_A^2 = 1$ .

$$r_A^3 = 1 - \frac{1}{\Delta_A Y^A} \sum_{\forall \varepsilon, k} \max \left\{ 0, \sum_{\forall j} \bar{a}_{j\varepsilon} x_{jk} - A \right\} : Y^A > 0, \quad (23)$$

si  $Y^A = 0 \Rightarrow r_A^3 = 1$

(mr.7) Proporción de planes del conjunto E satisfechos por la solución  $\zeta_0$ , según la limitación del riesgo R.

$$r_R^1 = 1 - \frac{1}{|E|} \sum_{\varepsilon=1}^{|\varepsilon|} \max_{k \in K} y_{k\varepsilon}^R \quad (24)$$

(mr.8) Proporción de estaciones sin sobre-riesgo ergonómico: proporción de estaciones cuyo riesgo ergonómico no excede al riesgo permisible R.

$$r_R^2 = 1 - \frac{1}{m} \sum_{k=1}^{|K|} \max_{\varepsilon \in E} y_{k\varepsilon}^R \quad (25)$$

(mr.9) Proporción del riesgo ergonómico adicional concedido ( $\Delta_R$ ) que no emplea la solución  $\zeta_0$ . Es igual a 1 cuando  $r_R^1 = 1$  o  $r_R^2 = 1$ .

$$r_R^3 = 1 - \frac{1}{\Delta_R Y^R} \sum_{\forall \varepsilon, k} \max \left\{ 0, \sum_{\forall j} \bar{R}_{j\varepsilon} x_{jk} - R \right\} : Y^R > 0, \quad (26)$$

si  $Y^R = 0 \Rightarrow r_R^3 = 1$

### V. EJEMPLOS ILUSTRATIVOS

#### A. Datos y condiciones

Adoptamos un caso de estudio de la línea de producción de motores mixtos de la fábrica de Barcelona de Nissan Motor Ibérica, evaluando la robustez de soluciones ante un conjunto de planes de demanda en un entorno industrial.

Los 7 planes seleccionados para este artículo ( $\varepsilon \in E$ ) tienen una demanda diaria de 270 motores; los detalles se recogen en la Tabla I.

TABLA I. DEMANDAS DIARIAS POR TIPO DE MOTOR Y PLAN ( $d_{i,\varepsilon}$ ) PARA LAS INSTANCIAS CATEGÓRICAS NISSAN-9ENG.I ( $\varepsilon \in E$ ).

$i \in I$	$\varepsilon = 1$	$\varepsilon = 2$	$\varepsilon = 3$	$\varepsilon = 6$	$\varepsilon = 9$	$\varepsilon = 12$	$\varepsilon = 18$
$p_1$	30	30	10	50	70	24	60
$p_2$	30	30	10	50	70	23	60
$p_3$	30	30	10	50	70	23	60
$p_4$	30	45	60	30	15	45	30
$p_5$	30	45	60	30	15	45	30
$p_6$	30	23	30	15	8	28	8
$p_7$	30	23	30	15	8	28	8
$p_8$	30	22	30	15	7	27	7
$p_9$	30	22	30	15	7	27	7
SUVs	90	90	30	150	210	70	180
Vans	60	90	120	60	30	90	60
Truck	120	90	120	60	30	110	30
Total	270	270	270	270	270	270	270

En la línea se fabrican hasta 9 tipos de motores distintos ( $p_1, \dots, p_9$ ) con diferentes destinos y características de montaje: los tres primeros tipos son para vehículos SUVs; los tipos  $p_4$  y  $p_5$  son para furgonetas (vans); y los cuatro últimos se destinan a camiones comerciales (trucks) de medio tonelaje. Para una demanda equilibrada (idéntica demanda para los 9 tipos) y un tiempo de ciclo de 3 minutos, la línea consta de 21 estaciones en serie con una longitud media de 4 metros cada una. El número de tareas elementales para fabricar un motor asciende a 380 y su agrupación da lugar a 140 tareas de montaje. En [5],[16] se pueden consultar los tiempos de proceso  $\bar{t}_{j\varepsilon}$ , las áreas lineales  $\bar{a}_{j\varepsilon}$ , las categorías de riesgo  $\chi_j$  y los conjuntos de precedencias  $P_j$  de las 140 tareas de montaje.

#### B. Resultados

Aquí analizamos cuatro configuraciones de línea mediante la aplicación de las métricas de robustez (mr.1-mr.9):

- Dos configuraciones de línea,  $\zeta_1$  y  $\zeta_2$ , con 18 estaciones, 180s de ciclo, 5,5 metros de área lineal por estación, 500 ergo-s de riesgo permitido y con coeficientes de flexibilidad ( $\gamma_c, \gamma_A, \gamma_R$ ) iguales al 5%. Las soluciones  $\zeta_1$  y  $\zeta_2$  se han obtenido mediante un IDEA adaptativo [7] y se muestran en las Tablas II y III.
- Dos configuraciones de línea,  $\zeta_3$  y  $\zeta_4$ , con 25 estaciones, 170s de ciclo, 3,5 metros de área lineal disponible por estación, 320 ergo-s de riesgo permitido y con coeficientes de flexibilidad ( $\gamma_c, \gamma_A, \gamma_R$ ) iguales al 5%. Las soluciones  $\zeta_3$  y  $\zeta_4$  se muestran en las Tablas IV y V y se han obtenido mediante un algoritmo GRASP [16], cuyo desempeño ha sido contrastado con PLEM.

TABLA II. CONFIGURACIÓN  $\zeta_1$  (18, 5,5, 500, 5%) IDEA ADAPTATIVO

$k$	$j \in S_k$ : carga de las estaciones										
1	1	7	8	9	11						
2	3	4	5	10	13	14					
3	6	12	16	17	19	20	21				
4	15	18	22	23	24	25	26	27	28		
5	2	29	30	31	32	34	36				
6	33	35	37	38	39	40	41	43			
7	42	44	45	46	47	48	49	59	60		
8	50	51	52	53	54	55	56	57	58		
9	61	62	63	64	65	66	67	70			
10	68	69	71	72	73	74	75				
11	76	77	78	79	80	81	82	83	84	86	
12	85	87	88	89	90	91	92	99			
13	93	94	95	96	98	100	101	103			
14	102	104	105	106	107	108	109	110	111	112	113
	114	115									
15	116	117	118	119	120	131					
16	121	122	123	128	132	134	135	136			
17	97	124	125	126	127	129	137	138	139		
18	130	133	140								

TABLA III. CONFIGURACIÓN  $\zeta_2$  (18, 5,5, 500, 5%) IDEA ADAPTATIVO

$k$	$j \in S_k$ : carga de las estaciones										
1	1	3	7	10	11						
2	4	5	8	9	13	14	18				
3	6	12	15	16	17	20					
4	22	23	24	25	28	29	30	31	32	34	
5	2	33	35	36	37	38					
6	39	40	41	42	43	44	45				
7	46	47	48	49	52	53	54	55	56		
8	50	51	57	58	59	60	61	62			
9	63	64	65	66	67	68	69	71	72		
10	70	73	74	75	76	77	78				
11	21	80	81	82	83	84	85	86	87	88	89
12	19	26	90	91	92	98					
13	27	94	95	99	100	101	102	103	104	108	109
	110	111									
14	107	112	113	114	115	116	117	118			
15	105	106	119	120	121	122	123	124			
16	79	93	128	131	132	134	135	136			
17	96	97	125	126	127	129	137	138	139		
18	130	133	140								

En las Tablas VI-IX mostramos los resultados resaltables para las cuatro configuraciones. Debemos hacer notar que las cuatro configuraciones son fuertemente robustas en atributos espaciales:  $y_{k\epsilon}^A = 0 (\forall k \in K, \epsilon \in E)$ .

La configuración  $\zeta_1$ . (Tabla VI) es fuertemente robusta en tiempo y en cuanto a riesgo ergonómico solo hay sobrecarga en las estaciones 7 y 12, en los 7 planes, por debajo del 5% de flexibilidad concedida. La configuración  $\zeta_2$  (Tabla VII) es casi fuertemente robusta en tiempos; en riesgo solo hay exceso en la estación 7 por debajo del 5% de flexibilidad concedida.

Por su parte, las configuraciones  $\zeta_3$  y  $\zeta_4$ , aun siendo semejantes, tienen distintas propiedades (Tablas VIII y IX). En efecto,  $\zeta_4$  es fuertemente robusta en riesgo y  $\zeta_3$  casi también lo es. En cuanto al tiempo de carga, tanto  $\zeta_3$  como  $\zeta_4$  exceden levemente el tiempo de ciclo.

A modo de resumen, la Tabla X recoge los valores de las 9 métricas para las 4 configuraciones  $\zeta_1 - \zeta_4 (\forall \epsilon \in E)$ .

TABLA IV. CONFIGURACIÓN  $\zeta_3$  (25, 3,5, 320, 5%) GRASP\_MAX

$k$	$j \in S_k$ : carga de las estaciones										
1	1	10									
2	13	14	11	3	9	18					
3	17	15	21	20	19						
4	5	4	6	16							
5	26	27	25	23	22	7					
6	24	28	29	30	8						
7	31	32	36	33	35	37	34				
8	39	40	38	43	41	59					
9	42	44	45	46	48						
10	49	47	50	54	55	53					
11	56	52	51	60	57	64					
12	58	61	62	63	66	67					
13	70	65	68	71	72						
14	73	69	74	76							
15	79	75	77	78	81	80	82				
16	83	84	85	86	88	87	89				
17	90	91	99	92							
18	98	100	101	102	94	103					
19	106	104	108	105	113	109	111	115	114	112	107
20	12	2	116	118							
21	119	120	117	131	132	134	135				
22	121	136	93	95	122						
23	123	124	125	126	127	96	129				
24	128	137	130	133	97						
25	138	139	140	110							

TABLA V. CONFIGURACIÓN  $\zeta_4$  (25, 3,5, 320, 5%) GRASP\_MED. SE MUESTRA LAS CARGA DE LAS ESTACIONES 9,10 Y 16-21. LAS CARGAS RESTANTES SON IDÉNTICAS A LAS DE LA CONFIGURACIÓN  $\zeta_3$ .

$k$	$j \in S_k$ : carga de las estaciones										
9	42	44	45	46	47						
10	49	48	50	54	55	53					
16	83	84	85	86	88	87	91				
17	90	89	99	92							
18	98	100	101	106	103						
19	102	104	108	105	113	109	111	115	114	112	94
20	12	2	116	119							
21	107	118	120	117	131	132	134	135			

TABLA VI. TIEMPOS DE CARGA Y RIESGO DE CARGA PARA LAS ESTACIONES SATURADAS O SOBRECARGADAS DE LA CONFIGURACIÓN  $\zeta_1$ .

Tiempos de carga $t(S_k)$								
$k \setminus \epsilon$	1	2	3	6	9	12	8	
3	178,0	178,2	177,3	179,1	180,0	177,8	179,6	
12	180,0	179,6	179,5	179,8	179,9	179,7	179,6	
17	180,0	179,6	179,5	179,6	179,7	179,7	179,4	
max	180,0	179,6	179,5	179,8	180,0	179,7	179,6	
$\Delta_{max}$	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
Riesgos de carga $R(S_k)$								
$k \setminus \epsilon$	1	2	3	6	9	12	18	
7	510,0	511,3	511,3	511,2	511,2	510,9	511,8	
12	520,0	518,8	518,4	519,3	519,3	519,1	518,9	
max	520,0	518,8	518,4	519,3	519,3	519,1	518,9	
$\Delta_{max}$	20,00	18,83	18,43	19,31	19,31	19,11	18,92	



TABLA VII. TIEMPOS DE CARGA Y RIESGO DE CARGA PARA LAS ESTACIONES SATURADAS O SOBRECARGADAS DE LA CONFIGURACIÓN  $\zeta_2$ .

Tiempos de carga $t(S_k)$							
$k \setminus \varepsilon$	1	2	3	6	9	12	18
15	180,0	179,9	179,8	180,0	180,1	179,9	180,0
17	180,0	179,6	179,6	179,5	179,5	179,7	179,3
max	180,0	179,9	179,8	180,0	180,1	179,9	180,0
$\Delta_{max}$	0,00	0,00	0,00	0,00	0,06	0,00	0,00
Riesgos de carga $R(S_k)$							
$k \setminus \varepsilon$	1	2	3	6	9	12	18
7	510,0	511,1	511,1	510,9	510,9	510,8	511,5
max	510,0	511,1	511,1	510,9	510,9	510,8	511,5
$\Delta_{max}$	10,00	11,09	11,13	10,94	10,94	10,83	11,46

TABLA VIII. TIEMPOS DE CARGA Y RIESGO DE CARGA PARA LAS ESTACIONES SATURADAS O SOBRECARGADAS DE LA CONFIGURACIÓN  $\zeta_3$ .

Tiempos de carga $t(S_k)$							
$k \setminus \varepsilon$	1	2	3	6	9	12	18
25	170,0	170,8	171,5	170,0	169,4	170,8	170,1
max	170,0	170,8	171,5	170,0	169,4	170,8	170,1
$\Delta_{max}$	0,00	0,78	1,45	0,03	0,00	0,82	0,08
Riesgos de carga $R(S_k)$							
$k \setminus \varepsilon$	1	2	3	6	9	12	18
20	320,0	320,1	319,9	320,2	320,2	320,0	320,3
max	320,0	320,1	319,9	320,2	320,2	320,0	320,3
$\Delta_{max}$	0,00	0,09	0,00	0,20	0,20	0,01	0,32

TABLA IX. TIEMPOS DE CARGA Y RIESGO DE CARGA PARA LAS ESTACIONES SATURADAS O SOBRECARGADAS DE LA CONFIGURACIÓN  $\zeta_4$ .

Tiempos de carga $t(S_k)$							
$k \setminus \varepsilon$	1	2	3	6	9	12	18
21	170,0	170,7	170,9	170,7	170,5	170,5	171,0
25	170,0	170,8	171,5	170,0	169,4	170,8	170,1
max	170,0	170,8	171,5	170,7	170,5	170,8	171,0
$\Delta_{max}$	0,00	0,78	1,45	0,66	0,54	0,82	0,97
Riesgos de carga $R(S_k)$							
$k \setminus \varepsilon$	1	2	3	6	9	12	18
20	320,0	318,9	318,8	319,0	319,0	319,3	318,5
max	320,0	318,9	318,8	319,0	319,0	319,3	318,5
$\Delta_{max}$	0,00	0,00	0,00	0,00	0,00	0,00	0,00

TABLA X. VALORACIÓN SEGÚN MÉTRICAS DE ROBUSTEZ -  $(mr. 1 - mr. 9)$  - DE LAS 4 CONFIGURACIONES DE LÍNEA  $\zeta_1 - \zeta_4$  ( $\forall \varepsilon \in E$ )..

	$r_c^1$	$r_c^2$	$r_c^3$	$r_R^1$	$r_R^2$	$r_R^3$	$r_A^{1,2,3}$
$\zeta_1$	1,00	1,00	1,00	0,00	0,89	0,91	1,00
$\zeta_2$	0,86	0,89	0,99	0,00	0,94	0,93	1,00
$\zeta_3$	0,29	0,96	0,97	0,29	0,96	1,00	1,00
$\zeta_4$	0,14	0,92	0,97	1,00	1,00	1,00	1,00

VI. CONCLUSIONES

Hemos definido 9 métricas de robustez para el problema TSALBP-ergo basándonos en trabajos previos para TSALBP. Nuestra propuesta, r-TSALBP-ergo, será útil en las siguientes circunstancias: (i) una línea de productos mixtos como sistema productivo, (ii) un ensamblado complejo con adiestramiento y especialización de los operarios y con tiempos de ciclo grandes (0.5'-15'), (iii) productos de grandes dimensiones (motores,

carrocerías, vehículos, etc.), (iv) lista de materiales compleja y con elevado número de componentes grandes y pesados, (v) estaciones largas (300cm-1000cm), (vi) valores de los atributos temporales, espaciales y de riesgo estables o con variabilidad controlada, y (vii) demanda variable de los productos.

En trabajos futuros, propondremos metaheurísticas y otros procedimientos híbridos, asistidos por la PLEM, para resolver diversas variantes del r-TSALBP-ergo.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía y Competitividad (Gobierno de España) con el proyecto TIN2014-57497-P (FHI-SELM2).

REFERENCIAS

- [1] Battaia, O., Dolgui, A., 2013. A taxonomy of line balancing problems and their solution approaches. *International Journal of Production Economics* 142, 259–277.
- [2] Boysen, N., Fliedner, M., Scholl, A., 2008. Assembly line balancing: Which model to use when? *International Journal of Production Economics* 111, 509–528.
- [3] Scholl, A., Becker, C., 2006. State-of-the-art exact and heuristic solution procedures for simple assembly line balancing. *European Journal of Operational Research* 168, 666–693.
- [4] Bautista, J., Pereira, J., 2007. Ant algorithms for a time and space constrained assembly line balancing problem. *European Journal of Operational Research* 177, 2016–2032.
- [5] Bautista, J., Batalla-García, C., Alfaro-Pozo, R. 2016. Models for assembly line balancing by temporal, spatial and ergonomic risk attributes. *European Journal of Operational Research* 251, 814–829.
- [6] Chica, M., Cordon, O., Damas, S., Bautista, J., 2013. A robustness information and visualization model for time and space assembly line balancing under uncertain demand. *International Journal of Production Economics* 145, 761–772.
- [7] Chica, M., Bautista, J., Cordon, O., Damas, S. 2016. A multiobjective model and evolutionary algorithms for robust time and space assembly line balancing under uncertain demand. *Omega* 58, 55–68.
- [8] Chica, M., Bautista, J., de Armas, J. 2018. Benefits of robust multiobjective optimization for flexible automotive assembly line balancing. *Flexible Services and Manufacturing Journal*, 1-29. <https://doi.org/10.1007/s10696-018-9309-y>
- [9] Beyer, H., Sendhoff, B., 2007. Robust optimization - a comprehensive survey. *Computer Methods in Applied Mechanics and Engineering* 196, 3190–3218.
- [10] Xu, W., Xiao, T., 2011. Strategic robust mixed model assembly line balancing based on scenario planning. *Tsinghua Science & Technology* 16, 308–314.
- [11] Simaria, A.S., Zanella de Sá, M., Vilarinho, P.M., 2009. Meeting demand variation using flexible u-shaped assembly lines. *International Journal of Production Research* 47, 3937–3955.
- [12] Dolgui, A., Kovalev, S., 2012. Scenario based robust line balancing: Computational complexity. *Discrete Applied Mathematics* 160, 1955–1963.
- [13] Li, J., Gao, J., 2014. Balancing manual mixed-model assembly lines using overtime work in a demand variation environment. *International Journal of Production Research* 52, 3552–3567.
- [14] Gurevsky, E., Battaia, O., Dolgui, A., 2012. Balancing of simple assembly lines under variations of task processing times. *Annals of Operations Research* 201, 265–286.
- [15] Hazir, Ö., Dolgui, A., 2013. Assembly line balancing under uncertainty: Robust optimization models and exact solution method. *Computers & Industrial Engineering* 65, 261–267.
- [16] Bautista-Valhondo, J., Alfaro-Pozo, R. 2018. A Case Study at the Nissan Barcelona factory to minimize the ergonomic risk and its standard deviation in a mixed-model assembly line. *Progress in Artificial Intelligence*, 1-12. <https://doi.org/10.1007/s13748-018-0153-9>



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

**MAEB 7.1: SESIÓN ESPECIAL:  
APLICACIONES DE  
SIMHEURISTICS EN  
LOGÍSTICA, TRANSPORTE Y  
CIUDADES INTELIGENTES**

**Organizadores:**

JAVIER FAULÍN, HELENA RAMALHINHO Y ÁNGEL JUAN







# Agile Optimization for Routing Unmanned Aerial Vehicles under Uncertainty

Javier Panadero\*, Alfons Freixes\*<sup>†</sup>, Jose M. Mozos\*, and Angel A. Juan\*<sup>†</sup>

\*IN3 - Computer Science Dept.

Universitat Oberta de Catalunya

Barcelona ,08018, Spain

{jpanaderom, jmozosr, ajuanp}@uoc.edu

<sup>†</sup>Euncet Business School

08225 Terrassa, Spain

afreixes@euncet.es

**Abstract**—The use of unmanned aerial vehicles (UAVs) is gaining popularity in contexts such as smart cities, city logistics, humanitarian logistics, natural disasters, or military operations. One optimization challenge directly related to the use of UAVs is the so-called team orienteering problem (TOP). In a TOP, each customer can either be visited only once by a single vehicle or not visited at all. Visiting each customer has associated a predefined reward, and the driving ranges of vehicles are typically limited by the duration of electric batteries. Due to the latter constraint, it is usual that not all customers can be visited. The main goal is then to find a set of open tours that maximizes the total collected reward without exceeding the fleet capacity nor the driving range limitation. In this paper, we consider the stochastic version of the problem, in which travel times are modeled as random variables following theoretical probability distributions. To solve this stochastic version of the TOP, a simheuristic algorithm combining a biased-randomized heuristic with simulation techniques is proposed. One of the main goals of our approach is to provide an ‘agile’ optimization methodology, i.e., one lightweight algorithm that can be easily implemented in real-life scenarios under uncertainty and, at the same time, can provide solutions in real-time (just a few seconds or even less).

**Index Terms**—Metaheuristics, simulation, team orienteering problem, unmanned aerial vehicles, agile optimization.

## I. INTRODUCTION

The term ‘smart city’ refers to a series of urban systems and domains that are interconnected, via information technologies (ITs), with the purpose of optimizing their operations and management [1]. Smart cities represent a multidisciplinary research field that is under a continuous updating process driven by urban, social, and technology evolution [2]. These advances are generating new services and products for citizens, which also arises new challenges in data gathering, data analytics, and efficient decision making.

Unmanned aerial vehicles (UAVs) are known for autonomous operation and mobility. Though there are first studies available [3] [4], the usage of UAVs in smart cities is not fully explored yet. Until today they were mainly used for and effectively integrated in military activities, surveillance, security, precision agriculture and goods and services deliveries [5] [6], while there are still concerns on their effective and reliable implementation in smart cities. With the use of a reliable and

intelligent transportation system (ITS), it would be possible to replace human road support teams by a set of UAVs overflying highways to monitor possible traffic violations and accidents, or for providing specific information to other transport users. Technological support for interacting with other transport users is given by the ITS, dedicating a short-range communication interface to UAV, which transmit information either vehicle-to-vehicle or vehicle-to-infrastructure. Using wireless links when being close to each other, connected UAV impose improved road safety and traffic efficiency. The execution of these specific roles requires coordination of and collaboration within a group of UAVs. In particular, there is a need to design effective routing plans for a group of UAVs that need to visit a series of locations in order to gather some information (e.g., aerial pictures or videos, etc.). Thus, technological progress is required in the fields of advanced algorithms and other IT-based support tools to ensure: (i) a safe and effective navigation of UAV within the transportation infrastructure [7]; (ii) predictive analytics fed by critical data, which are needed for an efficient use of energy; and (iii) the use of computer vision techniques and remote sensing information for processing aerial real-time video footage.

Initially proposed by [8], the team orienteering problem (TOP) is one realistic variation of the well-known vehicle routing problem [9]. The TOP is gaining interest both in the scientific community and the industry due to the increasing use of electric vehicles and unmanned aerial vehicles, where driving range limitations need to be taken into account [10]. Consider the following elements: (i) a set of customer nodes, each of them with an associated reward score that can be collected the first time a customer is visited by any UAV; and (ii) a team of  $m$  UAVs with limited driving-range capabilities. Then, the goal is to determine a set of  $m$  open routes (each of them connecting an *origin* depot with a *destination* depot), which maximizes the total collected reward by visiting a subset of available customers without violating the driving range constraint.

Notice that each customer can either be visited once or not visited at all. Also, due to the driving range limitation, it is possible that not all customers can be visited. Being an

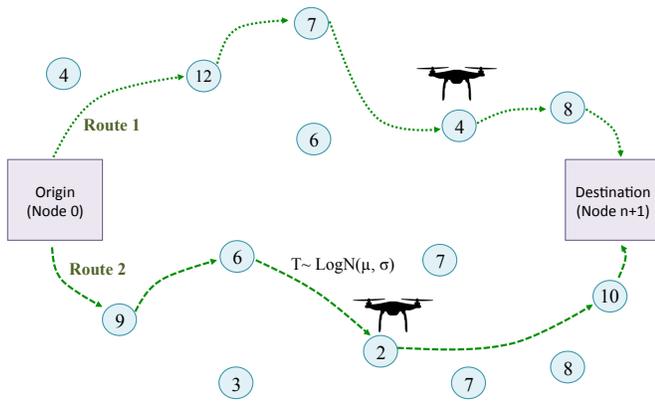


Fig. 1: Routing UAVs and the team orienteering problem

extension of the vehicle routing problem in which a subset of customers have to be selected and a set of routes covering them constructed, the TOP is also a *NP-hard* problem. Accordingly, different metaheuristic approaches have been proposed in recent years to deal with large-scale instances of the deterministic version of the problem. However, the stochastic counterpart, which considers real-life uncertainty in the form of random service and travel times, has received much less attention. This paper analyzes a stochastic TOP variant in which travel times are modeled as random variables (Figure 1). In particular, we consider the problem of recollecting as much reward as possible from visiting customers using a fleet of  $m$  UAVs with driving ranges limited by the time-duration of their batteries. An example of practical application could be the use of UAVs to take pictures of different locations after a natural disaster, a terrorist attack, or a humanitarian crisis. Notice that each of these pictures can provide valuable information that can help to improve the conditions of the people affected by the event or even to save their lives by making informed decisions on the more reliable evacuation paths.

Finding a solution (set of open routes) that maximizes the total expected reward is usually the main goal of the stochastic team orienteering problem (STOP). However, since solutions to the STOP are applied in a stochastic environment, other statistical properties should be considered too. Thus, for instance, one could be interested in solutions offering a high reliability level, i.e., routing plans with a low probability of violating the driving-range threshold.

This paper proposes a simulation-optimization algorithm to efficiently cope with the STOP. First, a biased-randomized heuristic for solving the deterministic TOP is introduced. This heuristic is then extended into a simheuristic algorithm [11] to solve the stochastic TOP. Due to their effectiveness, simheuristic algorithms are being increasingly used in solving different stochastic variants of the vehicle routing problem, like the stochastic inventory routing problem [12], the stochastic waste collection problem [13], or the stochastic arc routing problem [14].

The remaining sections of this paper are structured as follows: Section II reviews related work on the TOP. Sec-

tion III describes our biased-randomized heuristic for solving the deterministic TOP. Section IV describes our extension to a simheuristic to solve the STOP. A round of computational experiments for the STOP are described in Section V. Finally, Section VI summarizes the highlights of this paper and proposes some future research lines.

## II. RELATED WORK

The team orienteering problem was first introduced in [8]. To solve the TOP, they propose a heuristic approach where the stops that are farthest from the start and the finish nodes are selected as seeds for the team members, and all possible remaining points are inserted into the routes using the cheapest insertion rule. If unassigned points remain, new team routes are constructed. Additional approaches used to solve the deterministic TOP have been proposed in the literature. Although we can find some exact methods, such as branch-and-cut [15] or branch-and-cut-and-price algorithms [16] to solve the TOP, only small-scale instances can be solved with these methods.

[15] propose a particle swarm optimization (PSO) method to solve the TOP. Similarly, [17] present a multi-start simulated annealing (SA) algorithm to address the TOP. It integrates an SA stage inside a multi-start procedure to reduce the possibility of getting trapped in a local optima. Genetic algorithms (GA) have been also proposed in this area. For instance, [18] introduce a GA which imitates the natural process of evolution to solve the TOP. Other approach to solve the TOP is proposed by [19]. These authors present a Pareto mimic algorithm, which uses a mimic operator to generate a new solution by imitating an incumbent solution.

The stochastic version of the orienteering problem has only received attention in recent years. To the best of our knowledge, previous work has only considered the single-route problem rather than the STOP that we analyze here. There is also some variation in which aspects of the problem are stochastic. For example, the original stochastic single-vehicle orienteering problem (OP) [20] defines the OP with stochastic profits, which assumes that only the scores associated with each node are stochastic – in particular, it is assumed they follow a Normal probability distribution. There are also other works that study the OP with stochastic travel times [21]–[24]. This version can be classified as the orienteering problem with stochastic weights. Notice that our work extends these previous ones by considering multiple vehicles or routes.

In developing solutions to the STOP, one critical question is how to deal with open routes which exceed the designated time limit imposed by the driving-range constraint. In [25], exceeding the time limit incurs in a penalty cost that is proportional to the amount exceeding it. A similar approach is used in [26]. An alternative concept is presented in [27], where the probability of exceeding the time limit must be lower than a threshold value. The problem presented by [21] is partially different, since they do not force the vehicle to return to a set of depots but, instead, it can stop at any location once the time limit is reached. Also, penalties are incurred if a vehicle does



not manage to visit a scheduled node within the time limit. In contrast, [24] keep the hard constraint on the tour length that is used in the deterministic version of the problem and abort the route if the expected arrival time to the destination depot is equal to the remaining time. In the previous works, solving methodologies such as VNS metaheuristics and two-stage stochastic optimization were employed.

### III. A BIASED-RANDOMIZED HEURISTIC FOR ROUTING UAVS

A novel constructive heuristic for the TOP has been designed as a first step in our solving approach. One of the main goals of our proposed heuristic is to provide an ‘agile’ optimization methodology. The term ‘agile’ referring to software development methodologies (‘agile’ programming) was introduced by Beck et. al. [28], and it refers to any rapid and easy software development of high-quality. Inspired in this definition, we propose an ‘agile’ optimization methodology to develop optimization lightweight algorithms, which can be easily implemented in a short period of time, and they can be used in a efficient way in real-life scenarios under uncertainty, providing solutions in real-time (just a few seconds).

The proposed heuristic, which has been designed following this ‘agile’ optimization methodology, it is inspired on the well-known savings heuristic for the vehicle routing problem [29]. It has to be adapted to consider the particular characteristics of the TOP, i.e.: (i) the origin depot could be different from the destination one; (ii) not all the customers have to be visited; and (iii) the reward collected by visiting nodes must be considered during the construction of the routing plan. The goal was to design a new savings-based heuristic able to outperform the traditional one employed for solving the TOP [30].

Algorithm 1 provides a high-level description of the constructive heuristic. It starts by generating an initial dummy solution (line 1), in which one route per customer is considered –i.e., for each customer  $i \in A$ , a vehicle departs from the origin depot (node 0), visits  $i$ , and then resumes its trip towards the destination depot (node  $n + 1$ ) (Figure 2a). If any route in this dummy solution does not satisfy the driving-range constraint, the associated customer is discarded from the problem, since it cannot be reached with the current fleet of vehicles. Next, we compute the ‘savings’ associated with each edge connecting two different customers (line 2), i.e.: the benefits obtained by visiting both customers in the same route instead of using distinct routes.

In order to compute the savings associated with an edge, one has to consider both the travel time required to traverse that edge as well as the aggregated reward generated by visiting both customers. Thus, we define the concept of savings,  $s'_{ij}$  as described in Equation 1. Notice that it takes into account the trade-off between the classical time-based savings,  $s_{ij}$ , and the aggregated reward,  $u_i + u_j$ , i.e.:

$$s'_{ij} = \alpha \cdot s_{ij} + (1 - \alpha) \cdot (u_i + u_j) \quad (1)$$

#### Algorithm 1 Savings-based heuristic for the TOP

---

```

1: sol ← generateDummySolution(Inputs)
2: savingsList ← computeSortedSavingsList(Inputs, α)
3: while (savingsList is not empty) do
4:   arc ← selectNextArcAtRandom(savingsList, β)
5:   iRoute ← getStartingRoute(arc)
6:   jRoute ← getClosingRoute(arc)
7:   newRoute ← mergeRoutes(iRoute, jRoute)
8:   travelTimeNewRoute ← calcRouteTravelTime(newRoute)
9:   isMergeValid ← validateMergeDrivingCon-
      straints(travelTimeNewRoute, drivingRange)
10:  if (isMergeValid) then
11:    sol ← updateSolution(newRoute, iRoute, jRoute, sol)
12:  end if
13:  deleteEdgeFromSavingList(arc)
14: end while
15: sortRoutesByProfit(sol)
16: deleteRoutesByProfit(sol, maxVehicles)
17: return sol

```

---

where  $s_{ij} = t_{i(n+1)} + t_{0j} - t_{ij}$  (Figure 2b), and  $\alpha \in (0, 1)$ . The specific value of  $\alpha$  needs to be empirically tuned, since it will depend on the heterogeneity of the customers in terms of rewards. Thus, in a scenario with high heterogeneity,  $\alpha$  will be close to zero. On the contrary,  $\alpha$  will be close to one for homogeneous scenarios. Notice that for each edge there are two associated savings, depending on the actual direction in which the edge is traversed. Thus, each edge generates two different arcs.

After computing all the savings, the list of arcs can be sorted from higher to lower savings. Then, a route-merging process, based on the savings list, is started. In each iteration, the savings list of arcs is randomized using a biased probability distribution, and an arc is selected (line 4). As discussed in detail in Juan et al [31], the biased randomization of the savings list allows arcs to be selected in a different order in each iteration, where arcs with higher savings are more likely to be selected than those with lower savings, while at the same time, the logic behind the savings heuristic is maintained. In our case, a skewed Geometric Distribution is employed to induce this biased randomization behaviour. The Geometric Distribution uses one single parameter,  $\beta$ , which is relatively easy to set since  $0 < \beta < 1$ . After completing some preliminary tests with different values for  $\beta$  and analysing the corresponding outcomes, we decided to set  $\beta = 0.3$  in our computational experiments. The selected arc connects two routes, which are merged into a new route as far as this new route does not violate the driving-range constraint (line 9). Finally, the list of routes are sorted according to the total reward provided (line 15) to select as many routes from this list as possible taking into account the restricted number of vehicles in the fleet.

This heuristic is encapsulated within a multi-start process. This allows to run the biased-randomised heuristic several times, thus increasing our chances of finding a better solution.

### IV. A SIMHEURISTIC FOR ROUTING UAVS UNDER UNCERTAINTY

Algorithm 2 provides an overview of our multi-stage simheuristic approach, which extends the biased-randomized

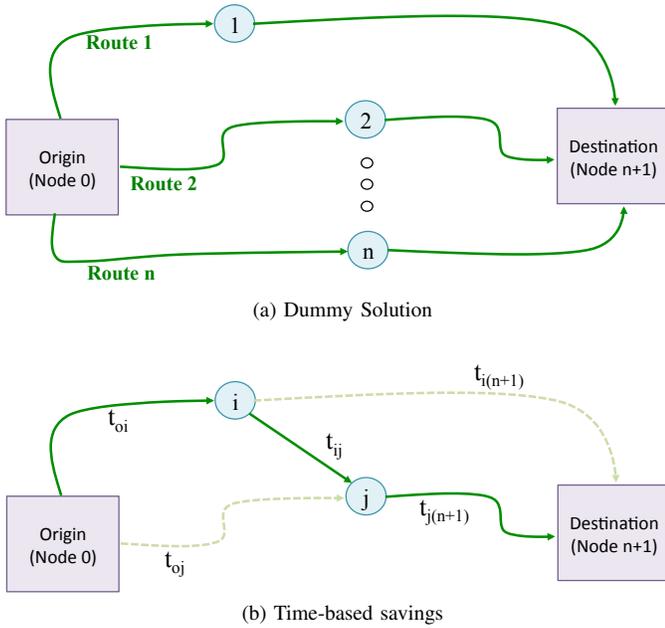


Fig. 2: Dummy solution (top) and time-based savings (down).

heuristic in order to deal with the STOP. In the first stage, a feasible initial solution (*initSolution*) is constructed using the savings-based heuristic described in Section III (line 1). During the second stage, an adaptive heuristic enhances the initial feasible solution by iteratively exploring the search space and conducting a ‘reduced’ number of simulation runs that allow to: (i) obtain observations on the total time employed by the current solution (from which the expected time and other statistics can be estimated); and (ii) provide feedback that can be used by the heuristic to better guide the search (e.g., by updating the base solution according to the estimated statistics). From this stage, a reduced set of ‘elite’ solutions is obtained.

Notice that during the second stage, whenever a *newSol* is ‘promising’, it is sent through a fast Monte Carlo simulation process (line 8) to estimate the following values: (i) the

---

#### Algorithm 2 Simheuristic approach

---

```

1: initSolution ← ComputeInitSolution(Inputs)
2: fastSimulation(solution)                                ▷ Monte Carlo Simulation
3: baseSol ← initSolution
4: while (ending condition is not met) do
5:   newSol ← savingBasedHeuristic(Inputs,  $\alpha$ ,  $\beta$ ) ▷ biased-randomized
     heuristic
6:   if (detProfit(newSol) improves detProfit(baseSol)) then
7:     fastSimulation(newSol)                                ▷ Monte Carlo Simulation
8:     if (stochProfit(newSol) improves stochProfit(baseSol)) then
9:       baseSol ← newSol
10:    if (stochProfit(baseSol) improves worstStochProfit(eliteSols))
then
11:      eliteSols ← update(eliteSols, baseSol)
12:    end if
13:  end if
14: end if
15: end while
16: return eliteSols

```

---

expected return; and (ii) its reliability, measured in terms of the percentage of routes that are effectively completed without violating the driving range constraint. Also, whenever the stochastic value of the *newSol* outperforms that of the *baseSol* and / or that of some elite solution (*eliteSols*), these solutions are updated to *newSol*.

#### V. COMPUTATIONAL EXPERIMENTS: STOCHASTIC CASE

There are not STOP instances to compare with in the literature. For that reason, we have extended the deterministic instances proposed in [8] into stochastic ones.

In our computational experiments, we have modeled the travel times  $T_{ij}$  using Log-Normal probability distributions. As discussed in [32], the Log-Normal distribution is a more natural choice than the Normal distribution when modeling non-negative random variables, such as the elapsed time until an event occurs (e.g., the time it takes the vehicle to traverse a given edge). In a real-world application, historical data could be used to model each  $T_{ij}$  by a different probability distribution. The Log-Normal has two parameters, namely: the location parameter,  $\mu$ , and the scale parameter,  $\sigma$ . According to the properties of the Log-Normal distribution, these parameters will be given by the following expressions considering stochastic travel times between nodes  $i$  and  $j$ :

$$\mu_{ij} = \ln(E[T_{ij}]) - \frac{1}{2} \ln \left( 1 + \frac{Var[T_{ij}]}{E[T_{ij}]^2} \right) \quad (2)$$

$$\sigma_{ij} = \left| \sqrt{\ln \left( 1 + \frac{Var[T_{ij}]}{E[T_{ij}]^2} \right)} \right| \quad (3)$$

In our experiments, which extend classical deterministic instances into stochastic ones, it is assumed that  $E[T_{ij}] = t_{ij}$  ( $\forall i, j \in N$ ), being  $t_{ij}$  the travel time provided in the deterministic instance. Similarly, it is considered that  $Var[T_{ij}] = c \cdot t_{ij}$ , being  $c \geq 0$  a design parameter. Notice that the deterministic instances are a particular case of the stochastic ones, which are obtained for  $c = 0$ . In our experiments, we have used the value  $c = 0.05$ .

The classic deterministic benchmarks consist of 7 different classes, Table I refers to class 1, and it shows: (i) the best-known solution for the deterministic variant of the problem (BKS), obtained from the existing TOP literature; (ii) our best solution for the deterministic variant of the problem (OBS-D); (iii) the computational time in seconds to obtain the OBS-D; (iv) the gap between the BKS and the OBS-D; (v) the reward of OBS-D when it is applied as a solution of the stochastic variant of the problem (OBS-D-S); (vi) our best solution for the stochastic variant of the problem (OBS-S); and (vii) the computational time in seconds to obtain the OBS-S.

Figure 3 shows, for the analyzed class, the percentage gaps between: (i) the best-found deterministic solution when applied into stochastic conditions (OBS-D-S) and itself when applied in a deterministic environment (OBS-D); and (ii) the best-found stochastic solution when applied into stochastic conditions (OBS-S) and the best-found solution for the deterministic version (OBS-D). Notice that the OBS-S boxplot is



TABLE I: Results for class 1 benchmark instances.

Instance	Deterministic execution				Stochastic execution		
	BKS Reward [1]	OBS-D Reward [2]	Time (s) [3]	Gap (%) [4](1-2)	OBS-D-S E[Reward] [5]	OBS-S E[Reward] [6]	Time (s) [7]
p1.2.b	15	15	0	0.0	14.3	14.3	4
p1.2.c	20	20	0	0.0	18.2	18.2	4
p1.2.d	30	30	0	0.0	26.0	26.3	4
p1.2.e	45	45	0	0.0	41.7	42.2	4
p1.2.f	80	80	0	0.0	64.6	70.5	5
p1.2.g	90	90	0	0.0	75.8	83.7	4
p1.2.h	110	110	0	0.0	97.5	103.6	17
p1.2.i	135	135	0	0.0	94.5	122.9	4
p1.2.j	155	155	0	0.0	123.1	141.0	5
p1.2.k	175	175	0	0.0	124.2	163.3	7
p1.2.l	195	195	5	0.0	125.8	179.5	9
p1.2.m	215	215	9	0.0	170.2	201.4	16
p1.2.n	235	235	0	0.0	152.9	218.8	5
p1.2.o	240	240	4	0.0	204.4	230.7	7
p1.2.p	250	250	0	0.0	167.3	230.9	5
p1.2.q	265	265	1	0.0	205.4	247.8	7
p1.2.r	280	280	21	0.0	168.9	259.9	4
p1.3.c	15	15	0	0.0	14.3	14.3	6
p1.3.d	15	15	0	0.0	15.0	15.0	6
p1.3.e	30	30	0	0.0	24.9	27.0	6
p1.3.f	40	40	0	0.0	31.8	32.6	23
p1.3.g	50	50	0	0.0	44.2	48.4	6
p1.3.h	70	70	1	0.0	66.3	66.3	11
p1.3.i	105	105	0	0.0	87.2	94.1	6
p1.3.j	115	115	0	0.0	90.7	102.2	6
p1.3.k	135	135	0	0.0	109.2	121.4	17
p1.3.l	155	155	0	0.0	124.0	138.8	13
p1.3.m	175	175	16	0.0	127.7	159.5	9
p1.3.n	190	190	1	0.0	152.2	175.1	15
p1.3.o	205	205	0	0.0	163.5	183.0	11
p1.3.p	220	220	1	0.0	177.5	199.0	32
p1.3.q	230	230	1	0.0	190.0	218.0	6
p1.3.r	250	250	17	0.0	207.2	233.5	27
p1.4.d	15	15	0	0.0	14.3	14.3	8
p1.4.e	15	15	0	0.0	15.0	15.0	8
p1.4.f	25	25	0	0.0	23.2	23.2	8
p1.4.g	35	35	0	0.0	30.1	34.3	8
p1.4.h	45	45	0	0.0	37.9	40.8	9
p1.4.i	60	60	0	0.0	48.5	55.0	8
p1.4.j	75	75	8	0.0	63.1	67.2	8
p1.4.k	100	100	27	0.0	86.3	86.3	8
p1.4.l	120	120	0	0.0	107.1	116.0	9
p1.4.m	130	130	0	0.0	112.0	124.9	10
p1.4.n	155	155	0	0.0	121.4	135.7	8
p1.4.o	165	165	0	0.0	129.6	149.0	28
p1.4.p	175	175	6	0.0	152.2	159.1	16
p1.4.q	190	190	6	0.0	167.1	171.9	8
p1.4.r	210	210	0	0.0	170.8	191.1	9
Average:			3	0.0			10

VI. CONCLUSION

The incorporation of unmanned aerial vehicles in urban areas describe promising research fields whose full potential are still to be explored in future. Still, these innovations raise a number of concerns and challenges that complicate decision-making processes for citizens and city managers. New hybrid optimization-simulation and optimization-machine-learning algorithms have to be developed to efficiently face these challenges. Scenarios for dynamic and uncertain real-life features have to be included.

ACKNOWLEDGMENT

This work has been partially supported by the Spanish Ministry of Economy and Competitiveness, FEDER (TRA2015-71883-REDT) and the Erasmus+ program (2016-1-ES01-KA108-023465).

REFERENCES

- [1] S. E. Bibri and J. Krogstie, "On the social shaping dimensions of smart sustainable cities: A study in science, technology, and society," *Sustainable Cities and Society*, vol. 29, pp. 219–246, 2017.
- [2] M. Angelidou, "Smart cities: A conjuncture of four forces," *Cities*, vol. 47, pp. 95–106, 2015.
- [3] A. G. Foïna, R. Sengupta, P. Lerchi, Z. Liu, and C. Krainer, "Drones in smart cities: Overcoming barriers through air traffic control research," in *Research, Education and Development of Unmanned Aerial Systems (RED-UAS), 2015 Workshop on*. IEEE, 2015, pp. 351–359.
- [4] O. B. Jensen, "Drone city-power, design and aerial mobility in the age of smart cities," *Geographica Helvetica*, vol. 71, no. 2, p. 67, 2016.
- [5] H. Menouar, I. Guvenc, K. Akkaya, A. S. Uluagac, A. Kadri, and A. Tuncer, "Uav-enabled intelligent transportation systems for the smart city: Applications and challenges," *IEEE Communications Magazine*, vol. 55, no. 3, pp. 22–28, 2017.
- [6] F. Mohammed, A. Idries, N. Mohamed, J. Al-Jaroodi, and I. Jawhar, "Opportunities and challenges of using uavs for dubai smart city," in *New Technologies, Mobility and Security (NTMS), 2014 6th International Conference on*. IEEE, 2014, pp. 1–4.
- [7] E. N. Barmounakis, E. I. Vlahogianni, and J. C. Golias, "Unmanned aerial aircraft systems for transportation engineering: Current practice and future challenges," *International Journal of Transportation Science and Technology*, vol. 5, no. 3, pp. 111–122, 2016.
- [8] I.-M. Chao, B. Golden, and E. Wasil, "The team orienteering problem," *European Journal of Operational Research*, vol. 88, pp. 464–474, 1996.
- [9] J. Caceres-Cruz, P. Arias, D. Guimarans, D. Riera, and A. A. Juan, "Rich vehicle routing problem: Survey," *ACM Computing Surveys (CSUR)*, vol. 47, no. 2, p. 32, 2015.
- [10] A. A. Juan, J. Goentzel, and T. Bektaş, "Routing fleets with multiple driving ranges: Is it possible to use greener fleet configurations?" *Applied Soft Computing*, vol. 21, pp. 84–94, 2014.
- [11] A. A. Juan, J. Faulin, S. E. Grasman, M. Rabe, and G. Figueira, "A review of simheuristics: Extending metaheuristics to deal with stochastic combinatorial optimization problems," *Operations Research Perspectives*, vol. 2, no. 1, pp. 62–72, 2015.
- [12] A. Gruler, J. Panadero, J. de Armas, J. A. M. Pérez, and A. A. Juan, "A variable neighborhood search simheuristic for the multiperiod inventory routing problem with stochastic demands," *International Transactions in Operational Research*, 2018.
- [13] A. Gruler, C. Fikar, A. A. Juan, P. Hirsch, and C. Contreras-Bolton, "Supporting multi-depot and stochastic waste collection management in clustered urban areas via simulation-optimization," *Journal of simulation*, vol. 11, no. 1, pp. 11–19, 2017.
- [14] S. Gonzalez-Martin, A. A. Juan, D. Riera, M. G. Elizondo, and J. J. Ramos, "A simheuristic algorithm for solving the arc routing problem with stochastic demands," *Journal of Simulation*, vol. 12, no. 1, pp. 53–66, 2018.
- [15] D.-C. Dang, R. N. Guibadj, and A. Moukrim, "An effective pso-inspired algorithm for the team orienteering problem," *European Journal of Operational Research*, vol. 229, no. 2, pp. 332–344, 2013.

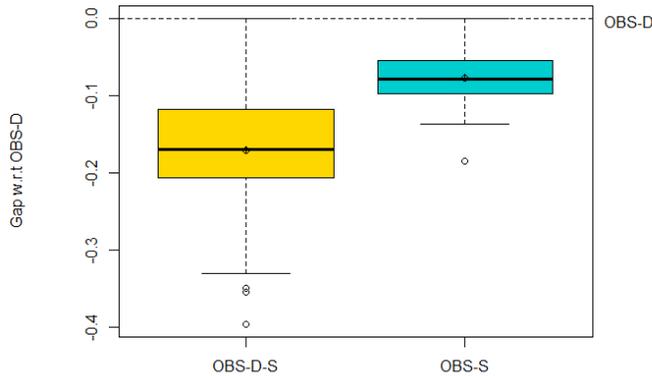


Fig. 3: Boxplot comparison of gaps OBS-D-S and OBS-S w.r.t. OBS-D.

always closer to the OBS-D value than the OBS-D-S boxplot. In other words, employing the best-found deterministic plan into a stochastic environment usually leads to suboptimal solutions. Notice also that the OBS-D value can be seen as an upper bound for the expected reward under stochastic conditions.

- [16] M. Keshtkaran, K. Ziarati, A. Bettinelli, and D. Vigo, "Enhanced exact solution methods for the team orienteering problem," *International Journal of Production Research*, vol. 54, pp. 591–601, 2015.
- [17] S. Lin, "Solving the team orienteering problem using effective multi-start simulated annealing," *Applied Soft Computing*, vol. 13, pp. 1064–1073, 2013.
- [18] J. Ferreira, A. Quintas, and J. Oliveira, "Solving the team orienteering problem: developing a solution tool using a genetic algorithm approach," in *Soft computing in industrial applications. Advances in Intelligent Systems and Computing: 223*. Springer, 2014, pp. 365–375.
- [19] L. Ke, L. Zhai, J. Li, and F. Chan, "Pareto mimic algorithm: an approach to the team orienteering problem," *Omega*, vol. 61, pp. 155–166, 2015.
- [20] T. Ilhan, S. Irvani, and M. Daskin, "The orienteering problem with stochastic profits," *IIE Transactions*, vol. 40, pp. 406–421, 2008.
- [21] A. Campbell, M. Gendreau, and B. Thomas, "The orienteering problem with stochastic travel and service times," *Annals of Operations Research*, vol. 186, pp. 61–81, 2011.
- [22] V. Papapanagiotou, R. Montemanni, and L. Gambardella, "Objective function evaluation methods for the orienteering problem with stochastic travel and service times," *Journal of Applied Operations Research*, vol. 6, pp. 16–29, 2014.
- [23] C. Verbeek, P. Vansteenwegen, and E.-H. Aghezzaf, "Solving the stochastic time-dependent orienteering problem with time windows," *European Journal of Operational Research*, vol. 255, pp. 699–718, 2016.
- [24] L. Evers, K. Glorie, S. van der Ster, A. Barros, and H. Monsuur, "A two-stage approach to the orienteering problem with stochastic weights," *Computers and Operations Research*, vol. 43, pp. 248–260, 2014.
- [25] S. Teng, H. Ong, and H. Huang, "An integer l-shaped algorithm for time-constrained traveling salesman problem with stochastic travel and service times," *Asia-Pacific Journal of Operational Research*, vol. 21, pp. 241–257, 2004.
- [26] H. C. Lau, W. Yeoh, P. Varakantham, D. T. Nguyen, and H. Chen, "Dynamic stochastic orienteering problems for risk-aware applications," *CoRR*, vol. abs/1210.4874, 2012. [Online]. Available: <http://arxiv.org/abs/1210.4874>
- [27] H. Tang and E. Miller-Hooks, "A tabu search heuristic for the team orienteering problem," *Computers & Operations Research*, vol. 32, no. 6, pp. 1379–1407, 2005.
- [28] K. Beck, M. Beedle, A. van Bennekum, A. Cockburn, W. Cunningham, M. Fowler, J. Grenning, J. Highsmith, A. Hunt, R. Jeffries, J. Kern, B. Marick, R. C. Martin, S. Mellor, K. Schwaber, J. Sutherland, and D. Thomas, "Manifesto for agile software development," 2001. [Online]. Available: <http://www.agilemanifesto.org/>
- [29] G. Clarke and J. Wright, "Scheduling of vehicles from a central depot to a number of delivery points," *Operations Research*, vol. 12, pp. pp. 568–581, 1964.
- [30] H. Tang and E. Miller-Hooks, "A tabu search heuristic for the team orienteering problem," *Computers & Operations Research*, vol. 32, no. 6, pp. 1379–1407, 2005.
- [31] A. A. Juan, J. Faulin, R. Ruiz, B. Barrios, and S. Caballé, "The sr-gcws hybrid algorithm for solving the capacitated vehicle routing problem," *Appl. Soft Comput.*, vol. 10, no. 1, pp. 215–224, Jan. 2010. [Online]. Available: <http://dx.doi.org/10.1016/j.asoc.2009.07.003>
- [32] A. A. Juan, J. Faulin, S. E. Grasman, D. Riera, J. Marull, and C. Mendez, "Using safety stocks and simulation to solve the vehicle routing problem with stochastic demands," *Transportation Research Part C: Emerging Technologies*, vol. 19, no. 5, pp. 751–765, 2011.



# A Simheuristic Algorithm for the Team Orienteering Problem

Javier Faulin\*, Angel A. Juan<sup>†‡</sup>, Lorena Reyes\*, Javier Panadero<sup>†</sup>, Carlos Ospina\*, Jose M. Mozos<sup>†</sup>

\*ISC - Institute of Smart Cities.

Public University of Navarre

Pamplona, 31006, Spain

{javier.faulin, lorena.reyes}@unavarra.es

cospinatrujillo@gmail.com

<sup>†</sup>IN3 - Computer Science Dept.

Universitat Oberta de Catalunya

Barcelona, 08018, Spain

{ajuana, jpanaderom, jmozosr}@uoc.edu

<sup>‡</sup>Euncet Business School

Terrassa, 08225, Spain

**Abstract**—Unmanned aerial vehicles (UAVs) or drones are being utilized by logistics systems in the context of smart cities. Here, we present a current application of the uses of drones through the Team Orienteering Problem (TOP). The TOP is a combinatorial optimization problem aimed at a practical approach for the urban transportation problems, such as traffic monitoring, freight transport, information transfer, safety, emergency situations management and other uses. This abstract copes with a TOP version in which a fleet of drones has to visit a series of customers. We assume that each visit to customers relies on a stochastic reward which implies a variable service time. Thus, a simheuristic algorithm is proposed as a solving approach integrating simulation inside a multi-start heuristic framework. A series of computational experiments contribute to illustrate the potential benefits of our work.

**Index Terms**—Team Orienteering Problem, stochastic Rewards, variable service times, simheuristic algorithm..

## I. INTRODUCTION

In a supply chain, a transport system is typically defined as a robust set of links that allows a continuous flow of resources such as information, money, and products. This set of links connects suppliers, production locations, retailers, and customers. The introduction of new technologies allows to consider real-time data that can be useful in order to identify suitable links at each time. Moreover, the European Commission has proposed different initiatives and some governmental projects to facilitate the emergence of sustainable and smart cities. Likewise, this transport system ensures quick responses to dynamic conditions of markets.

Practical applications of the TOP rely on stochastic rewards and service times associated to the customers visits. Hence, we propose a simheuristic algorithm to deal with a TOP with stochastic rewards and service times. This combinatorial optimization problem can be described as an undirected graph  $G = (N, A)$ , where  $N$  is a set of  $n$  nodes (including customers as well as an origin and a destination depot) and  $A = \{(i, j)/i, j \in N\}$  is the set of edges connecting all

nodes in  $N$ . Each customer  $i \in N$  has a stochastic reward ( $U_i$ ) and a service time ( $ST_i$ ). Similarly, each edge  $(i, j)$  is characterized by a traveling time ( $t_{ij}$ ). The total traveling time per route is limited by a driving range time ( $Tlim$ ), which represents the battery life of each UAV. The objective is to determine the subset of customers to be visited by each route (including the visiting order) which maximizes the expected reward considering the  $Tlim$  as a hard constraint.

The solution approach can be considered as a specialized case of simulation-based optimization, where only metaheuristics are employed as optimization components and the simulation feedback helps to better guide the metaheuristic searching process in a vast space of feasible solutions. In particular, our simheuristic algorithm combines Monte Carlo simulation (MCS) with a multi-start metaheuristic framework. All in all, our simheuristic approach aims at finding routing solutions offering both high expected rewards and reliability indexes. Finally, an expanded version of this work can be read in [1], which presents a stochastic version of the TOP using UAVs.

## II. SOLUTION APPROACH

Our solving approach relies on a simheuristic algorithm, it is composed of two different components: an optimization one—which searches for promising solutions—and a simulation one—which assesses the promising solutions in a stochastic environment and guides the searching process. Regarding the optimization component, we use a multi-start meta framework in which the constructive phase uses biased-randomization techniques [2], [3]. Figure 1 describes our simheuristic algorithm.

In the multi-start procedure, a feasible solution is built for deterministic version of the problem. There, the concept of ‘savings’ is introduced as a criterion for merging routes, and it is based on the savings in time associated with completing the merged route instead of the two original ones. This concept is extended to the concept of ‘preference’, which is a linear

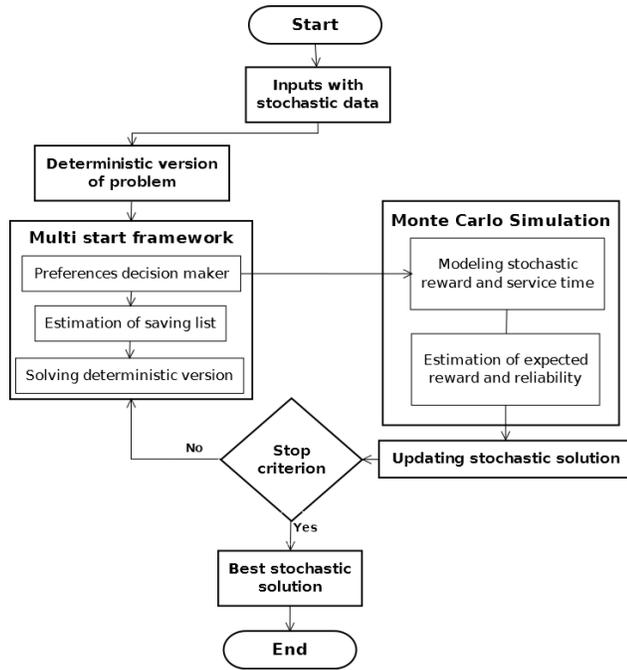


Fig. 1: Scheme of our algorithm.

combination of savings and accumulated rewards. Then, a merging that generates a greater accumulated reward will be prioritized over another one with similar time-based savings. Only a merging can be completed if the total expected time after the operation does not exceed the driving-range threshold. The concept of preference is used to generate a sorted list of potential mergings, and these are completed following the corresponding order, from higher to lower preference. Furthermore, we employ biased-randomization techniques, selecting the promising mergings using a probabilistic algorithm following a Geometric Distribution. Hence, merging operations with a larger preference are more likely to be selected.

Once a feasible solution with a high reward is determined, it is defined as the best deterministic solution. Then, MCS is incorporated to assess the quality of this solution, in terms of the expected reward and reliability (the probability that each route does not exceeds the driving-range). Thus, a feasible solution is iteratively constructed, building one element at a time in the multi-start procedure. As a result, the simulation procedure provides a feedback to simheuristic algorithm to better guide the searching process. At the end of this stage, the solution with the highest expected reward and reliability level is defined as the best stochastic solution.

### III. COMPUTATIONAL RESULTS

Since there are no benchmark instances for the TOP with stochastic rewards and constrained driving ranges, we modified and extended a deterministic data set from the literature. We assumed that the stochastic rewards,  $U_i$ , follow a Truncated Normal Distribution with parameters  $\mu(U_i)$  and  $\sigma(U_i)$ . The value of  $\sigma(U_i)$  is estimated as:  $c \cdot \mu(U_i)$ , where  $c$  is a parameter that allows exploring different levels of uncertainty. It is

TABLE I: Comparison of the simheuristic algorithm results and the best known solutions (BKS).

Instance	Tlim	BKS	BDS	BSS (a)	BDS* (b)	$\frac{b-a}{b}$ (%)
p3.4.t	27.5	670	670	487.29	485.50	0.37
p4.4.d	20	38	38	27.46	27.16	1.08
p5.4.v	27.5	1320	1320	938.63	901.8	4.17
<b>Average</b>						<b>1.88</b>

expected that as  $c$  converges to zero, the results from the stochastic version converge to those obtained in the deterministic scenario.

In order to validate the quality of our approach in the deterministic environment, where results are available in the literature, we compare our results with the best-known solution (BKS). We solve the 3 instances from the set  $d$  proposed by [4]. Each instance involves a number of UAVs (fleet size), number of nodes, and maximum route duration  $T_{lim}$ . The traveling time is estimated under the assumption that UAVs travel at a unitary speed. The performance of our approach is reported in the columns BDS, BSS, BDS\*, both for the deterministic and the stochastic environments solution. Notice that our simheuristic algorithm reaches the (deterministic) BKS for all tested instances, even when the run time was limited to 60 seconds.

Table I presents the expected reward associated with the deterministic solution BDS, which is compared with our best stochastic solution BDS\*. According to these results, the best stochastic solution provides an expected reward which is, on the average, up to 1.88% better than the expected reward provided by the best deterministic solution when employed in a stochastic environment. As a result, solutions for the deterministic version of the problem should not be used in solving the stochastic version, since they become suboptimal under uncertainty scenarios.

### IV. CONCLUSION

This work presents a simheuristic algorithm to solve a stochastic version of the TOP, where driving-range limitations of unmanned aerial vehicles are also considered. Under uncertain conditions is hardly to ensure feasible solutions, i.e., a route can request more time to be completed than the one provided by the battery duration. Our simheuristic algorithm allows to assess the quality of promising solutions and the estimation of the solution reliability.

### ACKNOWLEDGMENT

This work has been partially supported by the Spanish Ministry of Economy and Competitiveness (TRA2013-48180-C3-P and TRA2015-71883-REDT) FEDER, and the Ibero-American Program for Science and Technology for Development CYTED2014-515RT0489). Likewise, we want to thank the support of the UPNA doctoral program.



## REFERENCES

- [1] L. Reyes-Rubiano, J. M. Mozos, J. Panadero, C. Ospina-Trujillo, J. Faulin, and A. Juan, "The team orienteering problem with stochastic service times and driving-range limitations: A simheuristic approach. pending: presentation and publication," in *Proceedings of the 2018 Winter Simulation Conference*, M. Rabe, A. Juan, N. Mustafee, A. Skoogh, S. Jain, and B. Johansson, Eds., 2018.
- [2] A. A. Juan, I. Pascual, D. Guimarans, and B. Barrios, "Combining biased randomization with iterated local search for solving the multidepot vehicle routing problem," *International Transactions in Operational Research*, vol. 22, no. 4, pp. 647–667, 2015.
- [3] O. Dominguez, A. A. Juan, B. Barrios, J. Faulin, and A. Agustin, "Using biased randomization for solving the two-dimensional loading vehicle routing problem with heterogeneous fleet," *Annals of Operations Research*, vol. 236, no. 2, pp. 383–404, 2016.
- [4] I.-M. Chao, B. L. Golden, and E. A. Wasil, "The team orienteering problem," *European Journal of Operational Research*, vol. 88, no. 3, pp. 464–474, 1996.

# Current Trends in Simheuristics: from smart transportation to agent-based simheuristics

Alejandro Estrada-Moreno, Angel A. Juan, Javier Panadero, Carles Serrat, and Alfons Freixes

**Abstract**—Simheuristics extend metaheuristics by adding a simulation layer that allows the optimization component to deal efficiently with scenarios under uncertainty. This presentation reviews both initial as well as recent applications of simheuristics, mainly in the area of logistics and transportation. We also discuss a novel agent-based simheuristic (ABSH) approach that combines simheuristic and multi-agent systems to efficiently solve stochastic combinatorial optimization problems. The presentation is based on papers [1], [2], and [3], which have been already accepted in the prestigious Winter Simulation Conference.

**Index Terms**—simheuristics, stochastic optimization, logistics & transportation, agent-based simheuristics.

## I. INTRODUCTION

Real-life optimization problems are often *NP-hard* and large-scale in nature, which makes traditional exact methods inefficient to solve them. Thus, the use of heuristic and metaheuristic algorithms to obtain high-quality solutions in low computing times is required. With the increasing advances in computing hardware and software, simulation has become a ‘first-resource’ method for analyzing complex systems under uncertainty [4]. Thus, simulation is frequently employed in areas such as logistics and transportation, manufacturing, supply chain management, or smart cities. These systems are modeled and then simulated to get insights on their performance under different base scenarios. Simulation, however, is not an optimization tool. Thus, whenever a decision maker aims to find an optimal configuration for a system, she requires the use of optimization methods. Often, the associated optimization problems are addressed by assuming deterministic inputs and constraints, which allows us to simplify them but at the cost of not considering the real-life uncertainty that characterizes these systems.

Simheuristic algorithms integrate simulation methods inside a metaheuristic optimization framework to deal with large-scale and *NP-hard* stochastic optimization problems. Hybridization of simulation techniques with metaheuristics allows us to consider stochastic variables in the objective function of the optimization problem, as well as probabilistic constraints in its mathematical formulation. As discussed in [5], the simulation component deals with the uncertainty in the model and provides feedback to the metaheuristic component in order to guide the search in a more efficient way. Notice also that, when dealing with stochastic optimization problems, performance statistics other than expected values must be taken into account: while in deterministic optimization one can focus on finding a solution that minimizes cost or maximizes profits, a stochastic version of the problem might require

that we analyze other statistics such as its variance, different percentile values, or its reliability level.

The main goals of this presentation are: (i) to provide a commented review of recent applications of simheuristics in the area of transportation; and (ii) to analyze trends as well as open research lines.

## II. RECENT APPLICATIONS IN TRANSPORTATION

[6] discuss the need for optimizing urban waste collection in modern smart cities and formulate the problem as an extension of the vehicle-routing problem. The authors first develop a competitive metaheuristic, based on a variable neighborhood-search framework, to solve the deterministic variant. Then, they extend their approach into a simheuristic to cope with unexpected waste levels inside the containers. Their algorithm is tested using a large-scaled benchmark set for the waste-collection problem with several realistic constraints. Their results include a risk analysis considering the variance of the waste level and vehicle safety capacities.

The uncapacitated facility-location problem with stochastic service costs is analyzed in [7]. First, the authors propose an extremely fast savings-based heuristic, which generates real-time solutions for the deterministic version of the problem. This can be extremely useful in telecommunication applications, where ‘good’ solutions are needed in just a few milliseconds for large-scale networks.

[8] propose a simheuristic algorithm for solving the arc-routing problem with stochastic demands. Here, the authors use Monte Carlo simulation to extend the RandSHARP heuristic, which was originally designed to solve the deterministic version of the problem. During the design of the routing plan, they make use of safety stocks, which allow vehicles to deal with unexpectedly high demands during the actual distribution process.

[9] consider a stochastic version of the capacitated facility-location problem, proposing two facility-location models representing alternative distribution policies in e-commerce (outsourcing vs. in-house distribution). The multi-period inventory-routing problem with stochastic customer demands is analyzed in [10]. A variable neighborhood search is extended into a simheuristic algorithm to consider variations in the forecasted demands. With the aim of finding optimal refill policies for each customerperiod combination, the authors take into account that the quantity serviced at the beginning of one period will affect the inventory levels at the end of that period.



### III. CURRENT TRENDS

Some of the following trends in the use of simheuristics can be identified and are expected to play a relevant role in future publications on this topic, therefore constituting open research lines to be yet fully explored:

- *A higher level of simulation-optimization integration*: a deeper integration between the metaheuristic component and the simulation component, including increasing use of the feedback provided by the simulation better to guide the search for better solutions.
- *Additional objectives*: a rising interest in considering optimization goals different from the expected value of a solution for the stochastic optimization problem; this includes measuring other statistics reliability/robustness levels, and even considering multi-objective optimization problems.
- *Systems of increasing complexity*: moving from isolated logistics or transportation problems to integrated problems that reflect the complexity of supply networks, where interactions between different echelon stages also need to be considered in order to increase global efficiency.
- *Use of more sophisticated simulation approaches*: as the complexity of the systems increases, more advanced simulation approaches are required to take into account the dynamic and possibly nonstationary time-evolution of the system and the interactions among its many components.
- *Enhanced identification of promising solutions*: to speed up the computations, during a typical simheuristic process only a reduced set of solutions are classified as ‘promising’ and sent to the simulation component; enhanced strategies to classify a new solution as a promising one can be employed.
- *Statistically significant number of runs*: in some of the examples reviewed in this paper, a 2-stage approach is used; in the first stage the promising solutions are simulated using a reduced number of runs, while in the second stage longer simulations are executed on the ‘elite’ solutions provided in the first stage to increase the statistics’ accuracy and precision. However, statistical concepts could be employed to set the precise number of runs required in each stage in order to obtain estimates with a given level of precision.
- *Extending the application fields*: so far, most simheuristics have been applied in the area of transportation, logistics, and production. However, similar stochastic optimization problems can be found in other application fields such as telecommunications, finance, health-care systems, and smart cities.
- *Heuristic-supported simulation*: while the examples reviewed here refer to optimization problems in which simulation is used to support the search carried out by the metaheuristic, it is also possible to use heuristics or metaheuristics to optimize certain system parameters during a large simulation experiment.
- *Integration with machine learning*: being a flexible and relatively simple approach, simheuristics can be integrated with machine-learning approaches and, in particular, with learnheuristics in order to consider optimization problems with dynamic inputs.
- *Multi-population simheuristics*: all the examples reviewed here are based on single-population metaheuristics; however, integration of simulation within multi-population metaheuristics (e.g., genetic algorithms, etc.) might be worth exploring too since different individuals in a population might be based on different statistics obtained from the simulation component.
- *Agent-based simheuristics*: similar to the way agent-based modeling and simulation extends the more traditional concept of discrete-event simulation and benefits from distributed and parallel computing systems, one could consider agent-based simheuristics as a multi-agent extension of the simheuristic concept, where each agent is an autonomous and differentiated simheuristic algorithm that interacts with the rest of the agents while searching for a near-optimal solution to a complex and stochastic combinatorial optimization problem.

### REFERENCES

- [1] A. A. Juan, D. W. Kelton, C. Currie, and J. Faulin, “Simheuristics applications: dealing with uncertainty in logistics, transportation, and other supply chain areas,” in *Proceedings of the 2018 Winter Simulation Conference*, M. Rabe et al., Ed. Piscataway, New Jersey: IEEE Press, 2018.
- [2] J. Panadero, A. A. Juan, C. Corlu, J. Mozos, and S. Onggo, “Agent-based simheuristics: extending simulation-optimization algorithms via distributed and parallel computing,” in *Proceedings of the 2018 Winter Simulation Conference*, M. Rabe et al., Ed. Piscataway, New Jersey: IEEE Press, 2018.
- [3] A. Estrada-Moreno, C. Serrat, M. Nogal, M. Cavero, and A. A. Juan, “Distribution planning in a weather-dependent scenario with stochastic traveling times: a simheuristic approach,” in *Proceedings of the 2018 Winter Simulation Conference*, M. Rabe et al., Ed. Piscataway, New Jersey: IEEE Press, 2018.
- [4] T. W. Lucas, W. D. Kelton, P. J. Sanchez, S. M. Sanchez, and B. L. Anderson, “Changing the paradigm: Simulation, now a method of first resort,” *Naval Research Logistics (NRL)*, vol. 62, no. 4, pp. 293–303, 2015.
- [5] A. A. Juan, J. Faulin, S. E. Grasman, M. Rabe, and G. Figueira, “A review of simheuristics: Extending metaheuristics to deal with stochastic combinatorial optimization problems,” *Operations Research Perspectives*, vol. 2, pp. 62–72, 2015.
- [6] A. Gruler, C. L. Quintero, L. Calvet, and A. A. Juan, “Waste collection under uncertainty: a simheuristic based on variable neighbourhood search,” *European Journal of Industrial Engineering*, vol. 11, no. 2, pp. 228–255, 2017.
- [7] J. De Armas, A. A. Juan, J. M. Marquès, and J. P. Pedrosa, “Solving the deterministic and stochastic uncapacitated facility location problem: from a heuristic to a simheuristic,” *Journal of the Operational Research Society*, vol. 68, no. 10, pp. 1161–1176, 2017. [Online]. Available: <https://doi.org/10.1057/s41274-016-0155-6>
- [8] S. Gonzalez-Martin, A. A. Juan, D. Riera, M. G. Elizondo, and J. J. Ramos, “A simheuristic algorithm for solving the arc routing problem with stochastic demands,” *Journal of Simulation*, vol. 12, no. 1, pp. 53–66, 2018.
- [9] A. Pages-Bernaus, H. Ramalhinho, A. A. Juan, and L. Calvet, “Designing e-commerce supply chains: a stochastic facility location approach,” *International Transactions in Operational Research*, 2017.
- [10] A. Gruler, J. Panadero, J. DeArmas, J. A. Moreno-Perez, and A. A. Juan, “A variable neighborhood search simheuristic for the multi-period inventory routing problem with stochastic demands,” *International Transactions in Operational Research*, 2018.

# Designing e-commerce supply chains

## A stochastic facility–location approach

Adela Pagés-Bernaus  
Department of Mathematics  
University of Lleida  
Lleida, Spain  
adela.pages@matematica.udl.cat

Helena Ramalhinho  
Department of Economics and Business  
Universitat Pompeu Fabra  
Barcelona, Spain  
helena.ramalhinho@upf.edu

Angel A. Juan  
IN3 – Department of Computer Science  
Open University of Catalonia  
Barcelona, Spain  
ajuanp@uoc.edu

Laura Calvet  
IN3 – Department of Computer Science  
Open University of Catalonia  
Barcelona, Spain  
lcalvetl@uoc.edu

**Abstract**— e-Commerce activity has been increasing during recent years, and this trend is expected to continue in the near future. e-Commerce practices are subject to uncertainty conditions and high variability in customers’ demands. Considering these characteristics, we propose two facility–location models that represent alternative distribution policies in e-commerce. These models take into account stochastic demands as well as more than one regular supplier per customer. Two methodologies are then introduced to solve these stochastic versions of the well-known capacitated facility–location problem. The first is a two-stage stochastic-programming approach that uses an exact solver. However, we show that this approach is not appropriate for tackle large-scale instances due to the computational effort required. Accordingly, we propose a simheuristic approach that solves large-scale instances in short computing times. An extensive set of benchmark instances contribute to illustrate the efficiency of our approach, as well as its potential utility in modern e-commerce practices.

**Keywords**—component; formatting; style; styling; insert (key words)

### I. THE E-COMMERCE SUPPLY CHAIN DESIGN PROBLEM

The e-commerce in developed countries is steadily increasing, reaching a noticeable share of all commerce during the last years. One of the main strategic decisions that e-commerce enterprises must face is the location of their facilities or distribution centers (DCs). Note that this decision has an impact on the daily logistics activity and, consequently, on the customers’ quality of service.

This summary presents the work of Pagés-Bernaus (2017) [1] published recently. The work presents mathematical models that represent the decisions how the online distributors select the DC locations and how to perform the subsequent assignment of customers to these facilities.

The goal of this work is to study this supply-chain design problem and to analyze the impact of different delivery policies

in the presence of uncertainty. Since the capacity at each DC is limited, the problem is modeled as a Capacitated Facility Location Problem (CFLP) with stochastic demands. There are two CFLP variants differing in whether customers can be served from one DC (single source) or more (multiple source). In this paper, it is assumed that customers can be served from a number  $R$  of different facilities. So, each customer will have at most  $R$  facilities as regular providers. This variant is denoted as the CFLP with regular providers (CFLPrp).

### II. SOLUTION APPROACH AND COMPUTATIONAL RESULTS

To solve the proposed models, we propose two approaches: one based on Deterministic Equivalent Model (DEM) and another based on simheuristics methods, which in this case the method proposed hybridizes an ILS metaheuristic with simulation. The SimILS is an Iterated Local Search based method, where the local search stage focuses on providing configurations of open/closed facilities, as well as on the selection of the regular DCs. In the simulation stage, customers’ assignment decisions are made. Since the simulation stage is time-consuming, only “promising” solutions are tested in a stochastic environment.

The computational experiments are performed on the Beasley. For the small–medium instances, both approaches provide solutions of similar quality (with an average gap of  $-0.18\%$  for model A and  $-0.41\%$  for model B in favor of the stochastic-programming approach). However, the time employed by the SimILS approach is one order of magnitude smaller. Moreover, for the larger instances G4 the SimILS increases the required computing time but is able to provide feasible solutions.

### III. CONCLUSIONS

This summary presents two facility–location models, which consider stochastic demands as well as a restricted number of regular suppliers per customer. These models were inspired in



a real e-commerce supply design problem. We propose two different approaches to solve the models representing this problem. On the one hand, we use a two-stage stochastic-programming methodology. On the other hand, we propose a simheuristic algorithm, combining an ILS metaheuristic with simulation. According to the computational results obtained, the stochastic-programming approach is efficient but limited to small- and medium-sized instances. On the contrary, the proposed simheuristic approach is able to solve large-sized

instances in reasonable computing times, while providing also competitive results for smaller instances

#### REFERENCES

- [1] Pagès-Bernaus A., Ramalhinho H., Juan A.A., Calvet (2018), Designing E-commerce Supply Chains: a stochastic facility-location approach, *International Transactions in Operational Research* (First published: 3 July 2017). DOI: 10.1111/itor.12433.



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 7.2:  
ALGORITMOS MULTIOBJETIVO  
Y APLICACIONES







# Resumen extractivo de texto multidocumento usando un enfoque de optimización multiobjetivo basado en colonia de abejas artificiales

Jesus M. Sanchez-Gomez  
 Departamento de Matemáticas  
 Universidad de Extremadura  
 Cáceres, España  
 jmsanchezgoomez@unex.es

Miguel A. Vega-Rodríguez  
 Depto. Tecnología de Computadores y Comunicaciones  
 Universidad de Extremadura  
 Cáceres, España  
 mavega@unex.es

Carlos J. Pérez  
 Departamento de Matemáticas  
 Universidad de Extremadura  
 Cáceres, España  
 carper@unex.es

**Resumen**—Los métodos automáticos de resumen de texto son cada vez más necesarios en la actualidad. Los enfoques de resumen extractivo multidocumento pretenden obtener el contenido principal de una colección de documentos a la vez que reducen la información redundante, lo que puede ser abordado desde un enfoque de optimización multiobjetivo. En este trabajo se ha diseñado e implementado un algoritmo MOABC (*Multi-Objective Artificial Bee Colony*) para esta tarea. Los experimentos se han realizado en base a conjuntos de datos de DUC (*Document Understanding Conferences*), y se han evaluado con las métricas ROUGE (*Recall-Oriented Understudy for Gisting Evaluation*). Los resultados muestran mejoras importantes: del 31,09 % y del 18,63 % para el ROUGE-2 y del 8,43 % y del 6,09 % para el ROUGE-L, con respecto a los mejores resultados de enfoques mono-objetivo y multiobjetivo de la literatura científica. Además, se ha demostrado que los valores ROUGE obtenidos son más estables, con una reducción en la dispersión relativa de entre 620,63 % y 1333,95 %, es decir, entre 6 y 13 veces más robustos.

**Palabras clave**—Resumen de texto multidocumento, optimización multiobjetivo, colonia de abejas artificiales, cobertura del contenido, reducción de la redundancia.

## I. INTRODUCCIÓN

En la actualidad, la cantidad de información en Internet crece de forma exponencial en cualquier tema, y los usuarios desean obtener solo la información más relevante sobre dicho tema lo más rápido posible. Una forma de extraer esta información es mediante herramientas de minería de texto [1], con el fin de poder generar automáticamente un resumen a partir de toda la información del tema en cuestión [2], cubriendo la información más importante y evitando la redundancia de la misma.

Existen varios métodos de resumen automático: dependiendo de si la información se obtiene de uno o de más documentos, el resumen puede ser mono-documento o multidocumento [3]. Un resumen mono-documento reduce la información del documento a una breve representación, mientras que un resumen multidocumento selecciona información de toda la colección de documentos. Además, los métodos también pueden ser abstractivos o extractivos [4]. Los métodos abstractivos pueden construir un resumen con palabras o frases que no existen en el texto original, mientras que los métodos

extractivos seleccionan subconjuntos del texto original. El objetivo principal del resumen extractivo multidocumento es representar la información más importante en una versión reducida de los documentos originales, manteniendo los contenidos principales y reduciendo la redundancia. De esta manera, los usuarios pueden obtener las ideas principales del texto de forma rápida.

Como se ha definido, la naturaleza del resumen extractivo multidocumento es multiobjetivo, pero la mayoría de los enfoques en la literatura científica se basan en modelos de optimización mono-objetivo (p. ej. [5]). En estos enfoques solo se optimiza una función objetivo, la cual incluye a su vez varios objetivos que deben ser ponderados. Esta asignación de pesos es subjetiva, lo que influye mucho en la solución final. Hasta la fecha solo se ha propuesto un enfoque de optimización multiobjetivo [6], el cual ha obtenido mejores resultados que los enfoques mono-objetivo. Por lo tanto, el resumen automático de texto multidocumento mediante optimización multiobjetivo es una línea de investigación muy reciente, en la que la hipótesis principal es que al utilizar la optimización multiobjetivo se pueden obtener mejores resultados que con la optimización mono-objetivo.

En este trabajo, el resumen extractivo multidocumento es abordado mediante el algoritmo MOABC (*Multi-Objective Artificial Bee Colony*), el cual maximiza simultáneamente tanto la cobertura del contenido como la reducción de la redundancia de la colección de documentos. Los experimentos se han realizado en base al conjunto de datos de DUC (*Document Understanding Conferences*) y los rendimientos del modelo se han evaluado con las métricas ROUGE (*Recall-Oriented Understudy for Gisting Evaluation*). El enfoque propuesto ha obtenido resultados que mejoran las medias ROUGE de los mejores enfoques de la literatura científica, obteniendo además resultados más estables.

## II. TRABAJO RELACIONADO

En esta sección se muestra una revisión de las principales técnicas de optimización que se han implementado para el resumen extractivo multidocumento.

En primer lugar, se revisan los trabajos mono-objetivo, donde todos los objetivos son ponderados subjetivamente para obtener una función única. [7] consideró el resumen orientado a consultas de documentos como un problema de optimización global con cuatro objetivos, en el que los experimentos se realizaron con enfoques linealizados y lexicográficos. [8] propuso un método genérico de resumen multidocumento basado en la agrupación de oraciones, resolviéndolo con una modificación del algoritmo de optimización de enjambre de partículas (PSO). [9] diseñó un modelo de resumen de texto no supervisado basado en la programación lineal entera, que resolvió con un algoritmo de ramificación y poda (B&B) y un algoritmo PSO. [10] y [11] propusieron el resumen multidocumento como un problema de la  $p$ -mediana modificada, implementando [10] un algoritmo de evolución diferencial (DE) autoadaptativo y [11] un algoritmo de evolución diferencial basado en mutación y cruce autoadaptativos (DESAMC). [12] y [13] abordaron el resumen de documentos como un problema de programación no lineal 0-1, donde la función objetivo se definió como la media heroniana de los criterios, y el problema fue resuelto con el algoritmo PSO en ambos casos. [5] consideró el resumen de documentos como un problema de optimización discreta, proponiendo un algoritmo DE adaptativo para resolverlo. [14] y [15] consideraron la programación booleana cuadrática, donde la función objetivo era una combinación ponderada de los objetivos. En ambos casos se implementó un algoritmo DE binario. [16] propuso el resumen de documentos como un problema de programación entera cuadrática, resolviéndolo con un algoritmo PSO. [17] describió un enfoque basado en optimización para el resumen de documentos, implementando un algoritmo DE mejorado. [18] presentó el resumen de documentos como un problema de optimización lineal y no lineal, utilizando un algoritmo PSO para resolverlo. [19] describió el resumen multidocumento como un problema de optimización binaria, proponiendo un algoritmo de selección elitista intergeneracional, recombinación heterogénea y mutación cataclísmica (CHC). En [20], el resumen de texto se trató como un problema de programación booleana, que se resolvió con un algoritmo DE. Finalmente, [21] consideró el resumen multidocumento basado en el enfoque de proximidad tópica, para el cual se propuso un algoritmo DE autoadaptativo.

La optimización multiobjetivo resuelve los problemas de rendimiento de los modelos mono-objetivo, optimizando cada función objetivo sin ponderaciones. En el único trabajo multiobjetivo encontrado ([6]), se propuso un modelo de resumen extractivo multidocumento basado en la optimización discreta, implementando un algoritmo genético de ordenación no-dominada II (NSGA-II) para la resolución del problema.

Los principales objetivos incluidos en estos trabajos son la cobertura del contenido y la reducción de la redundancia. Sin embargo, también existen otros criterios como la relevancia, la coherencia y la significancia, pero no son tan comunes como los anteriores. Además, todos los trabajos llevaron a cabo la experimentación utilizando los conjuntos de datos de DUC y las métricas de evaluación ROUGE.

### III. DEFINICIÓN DEL PROBLEMA

En esta sección se define el resumen de texto multidocumento como un problema de optimización. Los métodos más usados en este contexto son los métodos de representación de vectores de términos (palabras), donde cada oración se representa como un vector de términos, y la similitud entre oraciones se compara por pares mediante el uso de algún criterio. El criterio mayormente utilizado es la similitud coseno, como en [5] y [6].

#### III-A. Similitud coseno

Dado el conjunto  $T = \{t_1, t_2, \dots, t_m\}$ , que contiene los  $m$  términos distintos de la colección de documentos  $D$ . Suponiendo un total de  $n$  oraciones, cada oración  $s_i$  de  $D$  se representa como un vector,  $s_i = (w_{i1}, w_{i2}, \dots, w_{im})$ ,  $i = 1, 2, \dots, n$ , donde cada elemento es el peso de su término correspondiente. Este peso  $w_{ik}$  está asociado con el término  $t_k$  en la oración  $s_i$ , y puede calcularse usando el esquema *frecuencia del término - frecuencia inversa de la oración* ( $tf\_isf$ ), donde  $tf$  mide cuántas veces aparece el término en una oración, e  $isf$  mide cuántas oraciones de  $D$  contienen el término [22], de la siguiente forma:

$$w_{ik} = tf_{ik} \cdot \log(n/n_k), \quad (1)$$

donde  $tf_{ik}$  cuenta cuántas veces aparece el término  $t_k$  en la oración  $s_i$ , y  $\log(n/n_k)$  es el factor  $isf$ , donde  $n_k$  denota el número de oraciones que contienen el término  $t_k$ .

El contenido principal de  $D$  se puede resumir cuantitativamente con la media de los pesos de los  $m$  términos en  $T$  con un vector medio  $o = (o_1, o_2, \dots, o_m)$ , donde cada componente se calcula como sigue:

$$o_k = \frac{1}{n} \sum_{i=1}^n w_{ik}, \quad k = 1, 2, \dots, m. \quad (2)$$

Finalmente, la similitud coseno se calcula a partir de los pesos previamente definidos, midiendo la semejanza entre las oraciones  $s_i = (w_{i1}, w_{i2}, \dots, w_{im})$  y  $s_j = (w_{j1}, w_{j2}, \dots, w_{jm})$  de la siguiente forma:

$$sim(s_i, s_j) = \frac{\sum_{k=1}^m w_{ik} w_{jk}}{\sqrt{\sum_{k=1}^m w_{ik}^2 \cdot \sum_{k=1}^m w_{jk}^2}}, \quad i, j = 1, 2, \dots, n. \quad (3)$$

#### III-B. Formulación del problema de optimización

Dado el conjunto  $D = \{d_1, d_2, d_3, \dots, d_N\}$ , que contiene  $N$  documentos.  $D$  también se puede representar como un conjunto que contiene las  $n$  oraciones de la colección como  $D = \{s_1, s_2, \dots, s_n\}$ . El objetivo es generar un resumen  $\bar{D} \subset D$  teniendo en cuenta los siguientes tres aspectos:

- *Longitud*: el resumen generado  $\bar{D}$  debe tener una longitud fija  $L$  (con cierta tolerancia).
- *Cobertura del contenido*: el tema principal de la colección de documentos  $D$  debe ser cubierto en el resumen  $\bar{D}$  incluyendo las oraciones apropiadas.



- *Reducción de la redundancia*: el resumen  $\bar{D}$  no debe ser redundante, es decir, las oraciones existentes en  $D$  que son similares entre sí no deben repetirse en el resumen generado.

Este problema de resumen de texto implica la optimización simultánea de la cobertura del contenido y de la reducción de la redundancia. Sin embargo, estos dos objetivos son contradictorios entre sí, por lo que un enfoque de optimización multiobjetivo es la forma natural de abordar este problema.

Sea  $x_i \in \{0, 1\}$  una variable de decisión binaria que considera la presencia ( $x_i = 1$ ) o la ausencia ( $x_i = 0$ ) de la oración  $s_i$  en el resumen generado  $\bar{D}$ . De esta forma, la representación de la solución (el vector de decisión) es la siguiente:  $x = (x_1, x_2, \dots, x_n)$ .

El primer objetivo a optimizar,  $\Phi_{cobertura}(x)$ , se refiere al criterio de la cobertura del contenido. Dada cada oración  $s_i \in \bar{D}$ , la cobertura del contenido se expresa en base a la similitud entre  $s_i$  y el conjunto de oraciones de  $D$  (representado por  $o$ ). Por lo tanto, la siguiente función debe ser maximizada:

$$\Phi_{cobertura}(x) = \sum_{i=1}^n sim(s_i, o) \cdot x_i. \quad (4)$$

El segundo objetivo a optimizar,  $\Phi_{red\_redund}(x)$ , se refiere a la redundancia de la información. En este caso, se define una variable de decisión binaria  $y_{ij}$  relacionada con la presencia simultánea ( $y_{ij} = 1$ ) o la ausencia ( $y_{ij} = 0$ ) de las oraciones  $s_i$  y  $s_j$  en el resumen generado  $\bar{D}$ . Para cada par de oraciones  $s_i, s_j \in \bar{D}$  la similitud  $sim(s_i, s_j)$  debe ser minimizada. Esto es equivalente a maximizar la reducción de la redundancia, esto es, a maximizar la siguiente función:

$$\Phi_{red\_redund}(x) = \frac{1}{(\sum_{i=1}^{n-1} \sum_{j=i+1}^n sim(s_i, s_j) \cdot y_{ij}) \cdot \sum_{i=1}^n x_i}. \quad (5)$$

Finalmente, el problema de optimización multiobjetivo del resumen extractivo multidocumento se formula como:

$$\text{máx } \Phi(x) = \{\Phi_{cobertura}(x), \Phi_{red\_redund}(x)\}, \quad (6)$$

$$\text{sujeto a } L - \varepsilon \leq \sum_{i=1}^n l_i \cdot x_i \leq L + \varepsilon, \quad (7)$$

donde  $l_i$  es la longitud de la oración  $s_i$  y  $\varepsilon$  es la tolerancia para la restricción de longitud del resumen, definida como:

$$\varepsilon = \max_{i=1,2,\dots,n} l_i - \min_{i=1,2,\dots,n} l_i. \quad (8)$$

#### IV. ABC MULTI OBJETIVO

El algoritmo ABC (*Artificial Bee Colony*) es un algoritmo de optimización basado en población que se fundamenta en el comportamiento inteligente de un enjambre o colonia de abejas [23]. El ABC simula el comportamiento de las abejas de la miel para resolver problemas de optimización. Principalmente, existen tres tipos de abejas: las abejas obreras, que mantienen las soluciones actualmente conocidas del problema; las abejas observadoras, que permiten la explotación de las mejores

soluciones encontradas hasta ahora; y las abejas exploradoras, que se encargan de la exploración de nuevas soluciones cuando algunas de las soluciones actuales se agotan (cuando no se pueden mejorar más).

Este algoritmo ha sido aplicado con éxito para resolver problemas del mundo real en múltiples contextos, ver p. ej. [24] y [25]. Además, algunos autores han propuesto nuevas variantes con el fin de mejorarlo (p. ej. [26] y [27]).

En esta sección se propone un algoritmo MOABC. Antes de describirlo, se explica el preprocesamiento de los documentos de entrada y los operadores de mutación y reparación.

##### IV-A. Preprocesamiento de entrada

Antes de la ejecución del algoritmo, los documentos de  $D$  deben ser preprocesados siguiendo estos pasos:

1. Segmentación. Las oraciones de  $D$  se extraen por separado para marcar el comienzo y el fin de cada una.
2. Tokenización. Las palabras (términos) de cada oración son separadas token a token. Los signos de puntuación, interrogación, exclamación... se eliminan en este paso.
3. Eliminación de las palabras vacías. Las palabras vacías de cada oración son eliminadas. Estas palabras son aquellas que carecen de significado principal, como artículos, preposiciones, conjunciones, etc. La lista de palabras vacías usada está proporcionada en el paquete ROUGE, y contiene 598 palabras [28].
4. *Stemming* del resto de palabras. Las raíces del resto de palabras son extraídas mediante el algoritmo de Porter [29], el cual ha sido ampliamente utilizado, convirtiéndose en el estándar para los métodos de análisis lexicográfico y para la recuperación de información en un amplio rango de lenguajes [30].

##### IV-B. Operador de mutación

La operación de mutación consiste en agregar o eliminar oraciones en el resumen correspondiente. Este operador se rige por la probabilidad de mutación  $p_m \in (0, 1)$ . Para cada oración en una solución  $x$  se genera un número aleatorio  $r_i \sim U(0, 1)$ . Si  $r_i \leq p_m$ , la oración  $s_i$  es candidata para la mutación, y si se cumple la siguiente condición:

$$sim(s_i, o) \geq \frac{1}{n} \sum_{j=1}^n sim(s_j, o), \quad (9)$$

$s_i$  se incluye en el resumen. De lo contrario, se elimina. Esta condición verifica si la similitud entre  $s_i$  y  $o$  es mayor o menor que la media de la similitud de las oraciones de  $D$ .

##### IV-C. Operador de reparación

El operador de reparación comprueba que el resumen generado no viola la restricción de longitud definida en la Ecuación 7. Antes de finalizar cada ciclo, cualquier resumen generado puede violar dicha restricción, la cual es verificada en ambas direcciones. Si el resumen generado tiene una longitud inferior a la restricción menos la tolerancia, el resumen es descartado, ya que el número de resúmenes generados en este caso es muy bajo (se ha verificado experimentalmente que estos

resúmenes se producen 6 veces menos que los resúmenes con una longitud superior a la restricción más la tolerancia). Por otro lado, si el resumen generado tiene una longitud superior a la restricción más la tolerancia, este resumen sí es reparado como se explica a continuación.

Dado el resumen generado  $D^*$ , que incumple la restricción de longitud, la operación de reparación elimina de  $D^*$  la o las oraciones más redundantes (las que tienen un alto grado de similitud entre ellas). Para esto se considera un umbral de similitud  $\delta = 0,9$  (una concordancia del 90%, también usada en [6]). Las siguientes condiciones son comprobadas para cada par de oraciones  $s_i$  y  $s_j$ :

$$\{s_i, s_j \in D^*\} \wedge \{i \neq j\} \wedge \text{sim}(s_i, s_j) \geq \delta \quad i, j = 1, 2, \dots, n. \quad (10)$$

Si estas condiciones se cumplen, entonces se usa el operador de reparación, eliminando la peor oración. Para ello, se calcula el siguiente valor de *calidad* para  $s_i$  y  $s_j$ :

$$\text{calidad}_{s_i} = \text{sim}(s_i, o) + ((\text{sim}(o^{\text{sum}}, o) - \text{sim}(o^{\text{sum}-s_i}, o)) \cdot 10, \quad (11)$$

donde  $\text{sim}(o^{\text{sum}}, o)$  es la similitud entre el centro del resumen generado (incluida la oración  $s_i$ ) y el centro de la colección de documentos  $o$ , y  $\text{sim}(o^{\text{sum}-s_i}, o)$  es la similitud entre el centro del resumen generado (excluyendo en este caso la oración  $s_i$ ) y el centro de la colección de documentos  $o$ . Este segundo término tiene un orden de magnitud mayor (se multiplica por 10), ya que mide la calidad del resumen cuando se elimina la oración  $s_i$ . Finalmente, la oración con la *calidad* más baja es eliminada del resumen, y este operador es aplicado hasta que la restricción de longitud requerida se cumple.

#### IV-D. Principales pasos del algoritmo

En esta subsección se propone una adaptación del algoritmo ABC para optimización multiobjetivo. Mientras que la optimización mono-objetivo devuelve la mejor solución encontrada, la optimización multiobjetivo devuelve un conjunto de soluciones que son no dominadas entre sí. Una solución es no dominada cuando ninguna de las funciones objetivo se puede mejorar sin que se degrade alguna de las otras [31]. El conjunto de soluciones no dominadas se conoce como conjunto de Pareto, y su representación gráfica como frente de Pareto.

El algoritmo MOABC se resume con el pseudocódigo del Algoritmo 1, que contiene los pasos principales del mismo.

En primer lugar, se inicializa el archivo de almacenamiento *Archivo\_NDS*, que contiene las soluciones no dominadas (línea 1). Después, la colonia inicial se genera aleatoriamente (línea 2), es decir, para cada solución (resumen), las oraciones de  $D$  se seleccionan de forma aleatoria. Los pasos de las líneas 3 a 11 se repiten durante un número máximo de ciclos  $\text{ciclos}_{\text{max}}$ .

En el paso de las abejas obreras (línea 4) se aplica una mutación para mejorar la solución, que será seleccionada solo si domina a la original. En la línea 5 se utilizan dos operadores para determinar cuáles son las mejores soluciones asociadas a las abejas obreras: *rank* y *crowding*. El primero clasifica las soluciones en diferentes frentes de Pareto según

#### Algoritmo 1 Pseudocódigo del MOABC.

```
1: Archivo_NDS  $\leftarrow \emptyset$ 
2: inicializar_colonia()
3: for ciclo = 1 to  $\text{ciclos}_{\text{max}}$  do
4:   enviar_abejas_obreras()
5:   rank_y_crowding(coloniatam)
6:   calcular_probabilidades()
7:   enviar_abejas_observadoras()
8:   enviar_abejas_exploradoras()
9:   rank_y_crowding( $2 * \text{colonia}_{\text{tam}}$ )
10:  exportar_colonia(Archivo_NDS)
11: end for
```

sus dominancias, mientras que el segundo da preferencia a las soluciones que aportan mayor diferenciación (a las más diversas) [32]. Una vez aplicados estos operadores, la selección se basa en las probabilidades calculadas en la línea 6, asignando mayores probabilidades a las mejores soluciones. En la línea 7 se envían las abejas observadoras, cuya tarea es seleccionar su abeja obrera asignada, teniendo en cuenta las probabilidades de selección, para tratar de mejorarla (el operador de mutación también es aplicado en este paso). En este punto del algoritmo, el tamaño de la colonia se duplica ( $2 * \text{colonia}_{\text{tam}}$ ). Las últimas abejas, las exploradoras (línea 8), se encargan de verificar las soluciones agotadas, que son aquellas que no han mejorado más después de un determinado número de intentos. Estas abejas agotadas son reemplazadas por exploradoras, que son nuevas soluciones generadas aleatoriamente. Para finalizar un ciclo, el tamaño de la colonia se reduce al tamaño original ( $\text{colonia}_{\text{tam}}$ ), aplicando los operadores *rank* y *crowding* nuevamente (línea 9), y se reparan las soluciones (cuando es necesario) para su almacenamiento en el archivo *Archivo\_NDS* (línea 10).

## V. RESULTADOS EXPERIMENTALES

### V-A. Conjuntos de datos

Los conjuntos de datos utilizados para medir el rendimiento han sido proporcionados por DUC (*Document Understanding Conferences*), siendo un banco de pruebas abierto de referencia para la evaluación de resúmenes automáticos. Las comparaciones se han realizado con los trabajos [5] y [6], donde se han utilizado 10 temas del conjunto de datos DUC2002 (del d061j al d070f) [33].

### V-B. Métricas de evaluación

El rendimiento del modelo se ha evaluado mediante el uso de las métricas ROUGE (*Recall-Oriented Understudy for Gisting Evaluation*) [34], que es considerada la métrica de evaluación oficial para los resúmenes por DUC. En este caso, las dos variantes de ROUGE usadas son: ROUGE-2 y ROUGE-L. Además de la media (M), se han considerado otras dos estadísticas para la medición de la dispersión: el rango y un coeficiente de variación estadístico. El rango (R) se calcula como  $R = \text{ROUGE}_{\text{mejor}} - \text{ROUGE}_{\text{peor}}$ . Sin embargo, no es adimensional, por lo que también se muestra una modificación



Tabla I

MEDIAS (M), RANGOS (R) Y COEFICIENTES DE VARIACIÓN (CV) DE LOS VALORES ROUGE-2 Y ROUGE-L. LOS MEJORES APARECEN SOMBREADOS.

Tema	ROUGE-2									ROUGE-L								
	DE adaptativo [5]			NSGA-II [6]			Enfoque propuesto			DE adaptativo [5]			NSGA-II [6]			Enfoque propuesto		
	M	R	CV	M	R	CV	M	R	CV	M	R	CV	M	R	CV	M	R	CV
d061j	0,266	0,290	109,02	0,306	0,263	85,95	0,365	0,093	25,43	0,542	0,208	38,38	0,554	0,205	37,00	0,590	0,056	9,46
d062j	0,188	0,275	146,28	0,200	0,422	211,00	0,342	0,023	6,60	0,473	0,239	50,53	0,481	0,306	63,62	0,536	0,017	3,26
d063j	0,245	0,208	84,90	0,275	0,279	101,45	0,272	0,005	1,84	0,493	0,156	31,64	0,528	0,171	32,39	0,509	0,050	9,74
d064j	0,194	0,280	144,33	0,233	0,356	152,79	0,308	0,009	2,83	0,462	0,235	50,87	0,488	0,287	58,81	0,495	0,011	2,19
d065j	0,144	0,209	145,14	0,182	0,208	114,29	0,198	0,026	13,32	0,431	0,141	32,71	0,457	0,174	38,07	0,464	0,057	12,29
d066j	0,201	0,257	127,86	0,181	0,245	135,36	0,290	0,019	6,54	0,455	0,196	43,08	0,441	0,149	33,79	0,519	0,007	1,36
d067f	0,239	0,235	98,33	0,260	0,298	114,62	0,356	0,005	1,39	0,509	0,232	45,58	0,529	0,244	46,12	0,580	0,012	2,15
d068f	0,491	0,384	78,21	0,496	0,281	56,65	0,444	0,084	18,83	0,666	0,226	33,93	0,626	0,226	36,10	0,639	0,071	11,09
d069f	0,184	0,166	90,22	0,232	0,239	103,02	0,240	0,008	3,15	0,454	0,135	29,74	0,476	0,191	40,13	0,554	0,010	1,81
d070f	0,224	0,260	116,07	0,262	0,215	82,03	0,305	0,002	0,76	0,496	0,173	34,88	0,513	0,158	30,80	0,515	0,005	0,90
<b>Media</b>	<b>0,238</b>	<b>0,256</b>	<b>114,03</b>	<b>0,263</b>	<b>0,281</b>	<b>115,72</b>	<b>0,312</b>	<b>0,027</b>	<b>8,07</b>	<b>0,498</b>	<b>0,194</b>	<b>39,13</b>	<b>0,509</b>	<b>0,211</b>	<b>41,68</b>	<b>0,540</b>	<b>0,030</b>	<b>5,43</b>

del coeficiente de variación tradicional de Pearson (CV), que implica la relación entre el rango y la media. Puede expresarse en términos de porcentaje como:

$$CV = \frac{R}{ROUGE_{media}} \cdot 100. \quad (12)$$

V-C. Configuración de los experimentos

Los parámetros del MOABC se han elegido para realizar comparaciones justas con los resultados de los enfoques propuestos en la literatura científica ([5] y [6]). Estos son: tamaño de colonia,  $colonia_{tam} = 50$ ; número de ciclos,  $ciclos_{max} = 1000$ ; probabilidad de mutación,  $p_m = 0,1$ ; y el número de repeticiones/ejecuciones independientes,  $reps_{max} = 20$ .

V-D. Resultados

Los resultados del MOABC son comparados con [6] (el único enfoque multiobjetivo existente en la literatura científica) y con [5] (el mejor enfoque mono-objetivo). La Tabla I presenta la media, el rango y el CV de los valores de ROUGE-2 y ROUGE-L para cada tema y los valores medios de todos los temas para los tres enfoques comparados.

En los resultados obtenidos en la Tabla I se puede observar que el enfoque propuesto supera a los otros dos, mejorando a [5] en 9 de los 10 temas y a [6] en 8 de 10 para el ROUGE-2, y en 9 de los 10 temas a ambos para el ROUGE-L. Además, los rangos y los CV muestran que los resultados del modelo propuesto son muy robustos. Considerando la media de los diez temas, para el ROUGE-2 el enfoque propuesto produce resultados con un CV medio de 8,07%, mientras que en los otros dos enfoques son de 114,03% y 115,72%. Para el ROUGE-L, mientras que el CV está alrededor del 40% en los otros enfoques, en el modelo propuesto el valor es solo del 5,43%. Finalmente, la Tabla II muestra las mejoras en términos promedio del enfoque propuesto con respecto a los otros enfoques.

Los resultados de la Tabla II dan lugar a las siguientes observaciones. En primer lugar, el enfoque propuesto mejora al presentado en [5], donde el algoritmo es un DE adaptativo mono-objetivo. La media del ROUGE-2 es mejorada en un

Tabla II

COMPARACIÓN DE LA MEDIA (M), DEL RANGO (R) Y DEL COEFICIENTE DE VARIACIÓN (CV) ENTRE EL ENFOQUE PROPUESTO Y LOS OTROS ENFOQUES.

Enfoque	Mejora del enfoque propuesto (%)					
	ROUGE-2			ROUGE-L		
	M	R	CV	M	R	CV
DE adaptativo [5]	31,09	848,15	1313,01	8,43	546,67	620,63
NSGA-II [6]	18,63	940,74	1333,95	6,09	603,33	667,59

31,09%, y la del ROUGE-L en un 8,43%. En segundo lugar, el enfoque propuesto también supera al presentado en [6]. En este caso, el algoritmo es un NSGA-II multiobjetivo. La media del ROUGE-2 tiene una mejora del 18,63%, y la del ROUGE-L del 6,09%. Finalmente, los rangos y CV muestran que los resultados del enfoque propuesto son mucho más robustos. Para el ROUGE-2, el enfoque propuesto mejora la media de los CV en más de un 1300% (13 veces más robusto), y para el ROUGE-L mejoran en más de un 600% (6 veces más robusto). Esto significa que las soluciones del MOABC son más estables que las obtenidas en los otros dos enfoques.

VI. CONCLUSIONES Y TRABAJO FUTURO

El problema de resumen multidocumento requiere la optimización de más de una función objetivo, por lo que es necesario aplicar enfoques de optimización multiobjetivo. Por primera vez, un enfoque basado en el algoritmo MOABC ha sido diseñado e implementado para este caso. Los resultados obtenidos no solo han mejorado en los valores ROUGE-2 (31,09% y 18,63% mejor) y en ROUGE-L (8,43% y 6,09% mejor), sino que también han mostrado una menor dispersión (alrededor de 1300% y 600% menos, es decir, alrededor de 13 y 6 veces más robusto) y, por lo tanto, la prueba de que el enfoque propuesto es estadísticamente más sólido que los enfoques comparables publicados.

Como línea de investigación futura, el enfoque se adaptará

para su aplicación en el software NeuroK<sup>1</sup>, que es una plataforma de *e-learning* basada en la neurodidáctica [35]. El algoritmo generará resúmenes de los contenidos de los estudiantes (mensajes, comentarios, observaciones o valoraciones), en unidades de aprendizaje o en actividades concretas, lo que será útil para los profesores de los cursos para muchos propósitos, incluida la evaluación automática para las calificaciones.

Otra línea de investigación interesante es el análisis del tiempo de CPU del algoritmo, con vistas a una posible paralelización para mejorar el tiempo de ejecución. Las técnicas basadas en programación paralela con OpenMP podrían ser muy útiles, ya que este enfoque permite explotar el paralelismo existente en las arquitecturas multinúcleo actuales.

#### AGRADECIMIENTOS

Esta investigación ha sido apoyada por el Ministerio de Economía y Competitividad (Centro para el Desarrollo Tecnológico Industrial, contrato IDI-20161039; Agencia Estatal de Investigación, proyectos TIN2016-76259-P y MTM2017-86875-C3-2-R), Junta de Extremadura (contrato AA-16-0017-1, y proyectos GR18108 y GR18090), Cátedra ASPgems y Unión Europea (Fondo Europeo de Desarrollo Regional).

#### REFERENCIAS

- [1] W. Fan y A. Bifet, "Mining big data: current status, and forecast to the future," *ACM SIGKDD Explorations Newsletter*, vol. 14, no. 2, 2013, pp. 1–5.
- [2] H. Hashimi, A. Hafez y H. Mathkour, "Selection criteria for text mining approaches," *Computers in Human Behavior*, vol. 51, 2015, pp. 729–733.
- [3] D. M. Zajic, B. J. Dorr y J. Lin, "Single-document and multi-document summarization techniques for email threads using sentence compression," *Information Processing & Management*, vol. 44, no. 4, 2008, pp. 1600–1610.
- [4] X. Wan, "An exploration of document impact on graph-based multi-document summarization," En *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, Association for Computational Linguistics, 2008, pp. 755–762.
- [5] R. M. Alguliev, R. M. Aliguliyev y C. A. Mehdiyev, "Sentence selection for generic document summarization using an adaptive differential evolution algorithm," *Swarm and Evolutionary Computation*, vol. 1, no. 4, 2011, pp. 213–222.
- [6] H. H. Saleh, N. J. Kadhim y B. A. Attea, "A Genetic Based Optimization Model for Extractive Multi-Document Text Summarization," *Iraqi Journal of Science*, vol. 56, no. 2, 2015 pp. 1489–1498.
- [7] L. Huang, Y. He, F. Wei y W. Li, "Modeling document summarization as multi-objective optimization," En *Intelligent Information Technology and Security Informatics (IITSI)*, 2010 Third International Symposium, IEEE, 2010, pp. 382–386.
- [8] R. M. Aliguliyev, "Clustering Techniques and Discrete Particle Swarm Optimization Algorithm for Multi-Document Summarization," *Computational Intelligence*, vol. 26, no. 4, 2010, pp. 420–448.
- [9] R. M. Alguliev, R. M. Aliguliyev, M. S. Hajirahimova y C. A. Mehdiyev, "MCMR: Maximum coverage and minimum redundant text summarization model," *Expert Systems with Applications*, vol. 38, no. 12, 2011, pp. 14514–14522.
- [10] R. M. Alguliev, R. M. Aliguliyev y C. A. Mehdiyev, "pSum-Sade: a modified p-median problem and self-adaptive differential evolution algorithm for text summarization," *Applied Computational Intelligence and Soft Computing*, vol. 2011, 2011, pp. 1–13.
- [11] R. M. Alguliev, R. M. Aliguliyev y N. R. Isazade, "DESAMC+ DocSum: Differential evolution with self-adaptive mutation and crossover parameters for multi-document summarization," *Knowledge-Based Systems*, vol. 36, 2012, pp. 21–38.
- [12] R. M. Alguliev, R. M. Aliguliyev y C. A. Mehdiyev, "An optimization model and DPSO-EDA for document summarization," *International Journal of Information Technology and Computer Science (IJITCS)*, vol. 3, no. 5, 2011, pp. 59–68.
- [13] R. M. Alguliev, R. M. Aliguliyev y N. R. Isazade, "Formulation of document summarization as a 0–1 nonlinear programming problem," *Computers & Industrial Engineering*, vol. 64, no. 1, 2013, pp. 94–102.
- [14] R. M. Alguliev, R. M. Aliguliyev y M. S. Hajirahimova, "Quadratic Boolean programming model and binary differential evolution algorithm for text summarization," *Problems of Information Technology*, vol. 3, no. 2, 2012, pp. 20–29.
- [15] R. M. Alguliev, R. M. Aliguliyev y M. S. Hajirahimova, "GenDocSum+MCLR: Generic document summarization based on maximum coverage and less redundancy," *Expert Systems with Applications*, vol. 39, no. 16, 2012, pp. 12460–12473.
- [16] R. M. Alguliev, R. M. Aliguliyev y N. R. Isazade, "CDDS: Constraint-driven document summarization models," *Expert Systems with Applications*, vol. 40, no. 2, 2013, pp. 458–465.
- [17] R. M. Alguliev, R. M. Aliguliyev y N. R. Isazade, "Multiple documents summarization based on evolutionary optimization algorithm," *Expert Systems with Applications*, vol. 40, no. 5, 2013, pp. 1675–1689.
- [18] R. M. Alguliev, R. M. Aliguliyev y C. A. Mehdiyev, "An optimization approach to automatic generic document summarization," *Computational Intelligence*, vol. 29, no. 1, 2013, pp. 129–155.
- [19] M. Mendoza, C. Cobos, E. Leon, M. Lozano, F. Rodriguez y E. Herrera-Viedma, "A new memetic algorithm for multi-document summarization based on CHC algorithm and greedy search," En *Mexican International Conference on Artificial Intelligence*, Springer, 2014, pp. 125–138.
- [20] R. M. Alguliev, R. M. Aliguliyev y N. R. Isazade, "An unsupervised approach to generating generic summaries of documents," *Applied Soft Computing*, vol. 34, 2015, pp. 236–250.
- [21] K. Umam, F. W. Putro, G. Q. O. Pratamasunu, A. Z. Arifin y D. Purwitasari, "Coverage, Diversity, and Coherence Optimization for Multi-Document Summarization," *Jurnal Ilmu Komputer dan Informasi*, vol. 8, no. 1, 2015, pp. 1–10.
- [22] G. Salton y C. Buckley, "Term-weighting approaches in automatic text retrieval," *Information Processing & Management*, vol. 24, no. 5, 1988, pp. 513–523.
- [23] D. Karaboga, "An idea based on honey bee swarm for numerical optimization," *Tech. rep.*, Technical Report-TR06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- [24] D. Karaboga y B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm," *Journal of Global Optimization*, vol. 39, no. 3, 2007, pp. 459–471.
- [25] D. Karaboga, B. Gorkemli, C. Ozturk y N. Karaboga, "A comprehensive survey: artificial bee colony (ABC) algorithm and applications," *Artificial Intelligence Review*, vol. 42, no. 1, 2014, pp. 21–57.
- [26] M. S. Kiran y O. Findik, "A directed artificial bee colony algorithm," *Applied Soft Computing*, vol. 26, 2015, pp. 454–462.
- [27] M. S. Kiran, H. Hakli, M. Gunduz y H. Uguz, "Artificial bee colony algorithm with variable search strategy for continuous optimization," *Information Sciences* 300, 2015, pp. 140–157.
- [28] ROUGE Summary Evaluation Package, <http://www.berouge.com/>. [Accedido 20-Julio-2017].
- [29] Porter stemming algorithm, <http://www.tartarus.org/martin/PorterStemmer/>. [Accedido 14-Junio-2018].
- [30] P. Willett, "The Porter stemming algorithm: then and now," *Program*, vol. 40, no. 3, 2006, pp. 219–223.
- [31] C. C. Coello, C. Dhaenens y L. Jourdan, "Advances in multi-objective nature inspired computing," *SCI*, vol. 272, Springer, 2010.
- [32] K. Deb, A. Pratap, S. Agarwal y T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, 2002, pp. 182–197.
- [33] Document Understanding Conference, <http://duc.nist.gov>. [Accedido 14-Junio-2018].
- [34] C.-Y. Lin, "Rouge: A package for automatic evaluation of summaries," En *Text summarization branches out: Proceedings of the ACL-04 workshop*, vol. 8, Barcelona, Spain, 2004, pp. 74–81.
- [35] F. Calle-Alonso, A. Cuenca-Guevara, D. de la Mata Lara, J. M. Sanchez-Gomez, M. A. Vega-Rodríguez y C. J. Perez Sanchez, "NeuroK: A Collaborative e-Learning Platform based on Pedagogical Principles from Neuroscience," En *Proceedings of the 9th International Conference on Computer Supported Education (CSEDU 2017)*, vol. 1, Science and Technology Publications, 2017, pp. 550–555.

<sup>1</sup><https://neurok.es/>



# Algoritmo Multiobjetivo de Colonia de Abejas Artificiales aplicado al Problema de Orientación

Rodrigo Martín-Moreno

*Depto. Tecnología de Computadores y Comunicaciones*  
*Universidad de Extremadura*  
 Cáceres, España  
 rmartinky@alumnos.unex.es

Miguel A. Vega-Rodríguez

*Depto. Tecnología de Computadores y Comunicaciones*  
*Universidad de Extremadura*  
 Cáceres, España  
 mavega@unex.es

**Resumen**—Hemos desarrollado un nuevo algoritmo para la resolución de problemas de orientación multiobjetivo, que tienen aplicación directa en el cálculo de rutas óptimas, logística, o bien el diseño de rutas turísticas, nuestra motivación principal. Los turistas priorizan según sus gustos el visitar puntos de interés, los cuales se pueden categorizar (p. ej. culturales u ocio), por lo que es necesaria la utilización de sistemas expertos multiobjetivo. Para conseguir las mejores soluciones de Pareto, hemos adaptado el algoritmo de colonia de abejas artificiales al contexto multiobjetivo. El rendimiento del algoritmo se ha comparado con dos algoritmos usados previamente en la literatura de los problemas de orientación multiobjetivo (P-ACO y P-VNS), y los resultados obtenidos indican que este nuevo algoritmo es acertado para resolver problemas de orientación multiobjetivo.

**Palabras clave**—Algoritmo de colonia de abejas artificiales, Optimización multiobjetivo, Problema de orientación, Inteligencia de enjambre, Computación evolutiva.

## I. INTRODUCCIÓN

Existe una gran variedad de sistemas de apoyo a la toma de decisiones, usados para diferentes propósitos como marketing, finanzas, logística o recursos humanos, por ejemplo. Sin embargo, existen pocos sistemas para ayudar a la gente a diseñar rutas turísticas que encajen en sus preferencias, más bien se les ofrece un conjunto de rutas prefijadas poco personalizables. Cuando los visitantes planean una visita a un destino, priorizan qué lugares o puntos de interés (POIs) merecen ser visitados, teniendo en cuenta su presupuesto, tiempo e interés y decidiendo su orden en la ruta. Por ello, un sistema de apoyo a la toma de decisiones, que ayude a los visitantes en este proceso, puede ser muy interesante. En todo caso, la decisión final recaerá siempre sobre el visitante, ya que el sistema solo ofrecerá las mejores soluciones para sus requerimientos, pero no contemplará la parte emocional de planear una visita a un destino.

El hecho de crear rutas que conecten POIs se define como un Problema de Orientación (OP) [1]. En este caso, nos centramos en el Problema de Orientación MultiObjetivo (MOOP), donde existen varias categorías para cada POI (p. ej.: cultural u ocio) y cada uno de ellos tiene diferentes beneficios para cada categoría. Hemos desarrollado un algoritmo MultiObjetivo de Colonia de Abejas Artificiales (MOABC), basándonos en el algoritmo mono-objetivo ABC propuesto por [2], para resolver el MOOP de una manera competitiva. Es la primera vez que

el algoritmo MOABC se aplica en la resolución de problemas de orientación multiobjetivo. Como veremos, los resultados obtenidos son muy competitivos al compararlos con los de otros algoritmos multiobjetivo (P-ACO y P-VNS) del estado del arte en este campo. Los experimentos han sido realizados en instancias de test e instancias del mundo real (un total de 216 instancias agrupadas en 10 conjuntos), y hemos usado tres indicadores de calidad para comparar los resultados.

Este artículo se estructura de la siguiente manera. La sección II introduce al lector en la investigación desarrollada en este campo. La sección III presenta la definición formal del problema y su formulación matemática. La sección IV desgrana nuestra estrategia multiobjetivo para resolver el problema. La sección V muestra los resultados obtenidos y compara los resultados de nuestro algoritmo con los de otros algoritmos previamente publicados. Por último, la sección VI culmina este artículo y muestra también posibles líneas de trabajo futuras.

## II. TRABAJO RELACIONADO

La optimización multiobjetivo ha sido un campo importante, con bastantes trabajos de investigación, en las dos últimas décadas. Dentro de ella, la resolución de MOOP es una área de gran aplicabilidad, aunque con poca actividad de investigación.

Hemos basado nuestro trabajo en el algoritmo ABC y lo hemos adaptado al contexto multiobjetivo. La elección del ABC se debe a que ha sido extensamente estudiado y aplicado para resolver problemas reales en múltiples campos [3], incluyendo optimización mono-objetivo (p. ej. [4], [5] y [6]) y optimización multiobjetivo (p. ej. [7], [8] y [9]).

Por otro lado, OP fue definido por [1], y algunos autores lo han considerado como un tipo de TSP (Problema del Viajante) con beneficios (ver [10]) o TSP selectivo. En OP, cada vértice tiene asociado algún beneficio, y la finalidad es visitar un grupo de vértices que maximice la suma de los beneficios, mientras se satisfaga la restricción de coste/longitud del tour. Dos estudios completos del estado del arte del problema de orientación se pueden encontrar en [11] y [12].

Relacionado con OP está el problema de orientación de equipo o TOP (ver [13] y [14]), donde el problema se extiende a múltiples tours.

Con respecto a MOOP, el problema abordado en este trabajo, muy pocas propuestas se pueden encontrar en la

literatura. Dentro del problema de orientación biobjetivo podemos destacar [15] que usó el algoritmo P-ACO (*Pareto Ant Colony Optimization*) y el algoritmo P-VNS (*Pareto Variable Neighborhood Search*) combinados con PR (*Path Relinking*), [16] que usó un algoritmo evolutivo también combinado con PR y [17] que utilizó GRASP combinado con PR.

### III. DEFINICIÓN DEL PROBLEMA MOOP

Puede modelarse como un grafo dirigido  $G = (V, A)$  con un conjunto de vértices,  $V = \{v_0, v_1, v_2, \dots, v_{n+1}\}$ , y un conjunto de aristas,  $A = \{(v_i, v_j) : v_i, v_j \in V \wedge v_i \neq v_j \wedge v_i \neq v_{n+1} \wedge v_j \neq v_0\}$ . Cada vértice  $v_i \in V \setminus \{v_0, v_{n+1}\}$  tiene asociados  $K$  beneficios  $b_{ik}$  ( $k = 1, \dots, K$ ). Los vértices inicial y final,  $v_0$  y  $v_{n+1}$ , no tienen beneficios asociados. Además, cada arista  $(v_i, v_j) \in A$  tiene un coste  $c_{ij}$  que puede ser interpretado como distancia, dinero o tiempo invertido para ir desde  $v_i$  hasta  $v_j$ .

En todas las instancias usadas en este trabajo,  $v_0$  y  $v_{n+1}$  representan el mismo punto, por lo tanto, entendemos que cada solución es un “tour” en lugar de “ruta”. La finalidad del problema de orientación multiobjetivo es encontrar los mejores tours (que maximicen los beneficios para todos los objetivos) desde  $v_0$  hasta  $v_{n+1}$ , cumpliendo la restricción marcada de coste/longitud  $C_{max}$ .

Podemos definir matemáticamente el problema como:

$$\text{maximizar } F(x) = (f_1(x), \dots, f_K(x)), \quad (1)$$

$$f_k = \sum_{v_i \in V \setminus \{v_0, v_{n+1}\}} (b_{ik} \cdot y_i) \quad (k = 1, \dots, K), \quad (2)$$

donde  $y_i$ , una variable binaria, toma valor 1 cuando  $v_i$  es visitado, y 0 en caso contrario. Además, hay que tener en cuenta que:

$$\sum_{v_i \in V \setminus \{v_j\}} a_{ij} = y_j \quad (v_j \in V \setminus \{v_0\}), \quad (3)$$

$$\sum_{v_j \in V \setminus \{v_i\}} a_{ij} = y_i \quad (v_i \in V \setminus \{v_{n+1}\}), \quad (4)$$

$$\sum_{\{v_i, v_j\} \in S} a_{ij} \leq |S| - 1 \quad (S \subseteq V \wedge S \neq \emptyset), \quad (5)$$

$$y_0 = y_{n+1} = 1, \quad (6)$$

$$\sum_{(v_i, v_j) \in A} c_{ij} \cdot a_{ij} \leq C_{max}, \quad (7)$$

$$a_{ij} \in \{0, 1\} \quad \left( (v_i, v_j) \in A \right), \quad (8)$$

$$y_i \in \{0, 1\} \quad (v_i \in V). \quad (9)$$

La variable binaria  $a_{ij}$  toma valor 1 cuando  $(v_i, v_j) \in A$  es usado, y 0 en caso contrario. La ecuación 1 indica que para resolver MOOP hay que maximizar las diferentes funciones objetivo. La ecuación 2 define cada función objetivo como la suma de sus beneficios correspondientes. Las ecuaciones 3 y 4 implican que para cada vértice visitado solo existe una arista entrante y una arista saliente. La ecuación 5 impide subtours. La ecuación 6 implica que los puntos de comienzo y fin se

usan en todos los tours. La ecuación 7 garantiza que el coste del tour no es superior al límite establecido  $C_{max}$ . En este caso, resolveremos el problema de orientación biobjetivo, por lo que  $K = 2$ .

### IV. SOLUCIÓN. NUEVO ALGORITMO MULTI OBJETIVO

En [18] se demostró que OP es NP-hard. Por ello, es necesario aplicar técnicas metaheurísticas en la resolución del problema de orientación multiobjetivo.

En esta sección explicamos el algoritmo MOABC que hemos diseñado y desarrollado. Inicialmente el algoritmo Colonia de Abejas Artificiales fue propuesto por [2] en el contexto mono-objetivo. Nosotros lo hemos adaptado al contexto multiobjetivo y particularmente a la resolución del problema de orientación multiobjetivo. Modelamos cada solución en MOOP como una lista de puntos (aquellos que se han incluido en el tour correspondiente), lo cual es la manera más natural para representar una solución para este problema.

#### IV-A. Optimización Multiobjetivo

Debido a la naturaleza multiobjetivo del problema a resolver, es muy difícil elegir una solución óptima donde todos los objetivos se maximicen. Sin embargo, si restringimos a soluciones no dominadas, la elección se limitará a un conjunto razonable de soluciones candidatas. Las siguientes definiciones ayudarán a clarificar este aspecto.

Una solución  $x$  domina a una solución  $x'$  si  $x$  no es peor que  $x'$  en ninguna de las funciones objetivo, y es mejor en al menos una de las funciones objetivo. Formalmente: para maximizar  $F(x) = (f_1(x), \dots, f_K(x))$ ,  $x$  domina  $x'$  si  $f_k(x) \geq f_k(x')$  para todo  $k = 1, \dots, K$ , y  $f_k(x) > f_k(x')$  para al menos un  $k$ . Si esto ocurre, escribimos  $x \succ x'$ .

Si ninguna solución domina a la solución  $x^*$ , decimos que  $x^*$  es no dominada o Pareto eficiente. En este caso, decimos que  $z^* = F(x^*) = (f_1(x^*), \dots, f_K(x^*))$  es un vector no dominado. El conjunto de todos los vectores no dominados es llamado frente de Pareto. La relación  $\succ$  puede ser extendida desde el espacio de soluciones al espacio de objetivos. En ese caso, dados dos vectores  $z = (z_1, \dots, z_K)$  y  $z' = (z'_1, \dots, z'_K)$ , escribimos  $z \succ z'$  si  $z_k \geq z'_k$  para todo  $k = 1, \dots, K$  y  $z_k > z'_k$  en al menos un  $k$ .

#### IV-B. MOABC

El algoritmo ABC es un algoritmo metaheurístico, basado en inteligencia de enjambre, que se inspira en el comportamiento alimenticio de las colonias de abejas melíferas y se compone de tres componentes principales: abejas obreras, abejas observadoras y abejas exploradoras. Las abejas obreras buscan fuentes de alimento (soluciones). Existen otros dos comportamientos interesantes que se requieren para la auto-organización y la inteligencia de enjambre: enviar nuevas abejas (abejas observadoras) hacia las fuentes de alimento prometedoras (feedback positivo) y abandonar fuentes de alimento agotadas (feedback negativo), generando abejas exploradoras.

Como hemos mencionado anteriormente, hemos adaptado el algoritmo ABC original al contexto multiobjetivo y en particular a la resolución de MOOP. Un pseudocódigo de nuestro



algoritmo MOABC se muestra en algoritmo 1. Las siguientes subsecciones detallan todas las partes de este algoritmo.

---

**Algoritmo 1** Colonia de Abejas Artificiales Multiobjetivo

---

**entrada:**  $T_{max}$  (tiempo máximo de ejecución),  $TP$  (tamaño de la población) y  $limite$  (criterio de abandono)

**salida:**  $Fichero\_SND$  (fichero con las soluciones no dominadas)

```

1:  $t \leftarrow 0$ ;  $Fichero\_SND \leftarrow \emptyset$ 
2: IniciarFuentesAlimento( $TP$ )           ▷ ver IV-C
3: while  $t < T_{max}$  do
4:   FaseAbejasObreras( $TP$ )             ▷ ver IV-D
5:   CalcularCantidadNectar( $TP$ )       ▷ ver IV-E
6:   FaseAbejasObservadoras( $TP$ )      ▷ ver IV-F
7:   FaseAbejasExploradoras( $TP$ ,  $limite$ ) ▷ ver IV-G
8:   GuardarSND( $Fichero\_SND$ )        ▷ ver IV-H
9: end while

```

---

#### IV-C. Iniciar Fuentes de Alimento

Todas las soluciones (fuentes de alimento) de la población ( $TP$ : tamaño de la población) se generan aleatoriamente por las abejas obreras siguiendo estos pasos: primero calculamos los 20 mejores movimientos desde cada punto a cualquier otro. Este cálculo solo se realiza una vez y se usa cuando sea necesario. Los mejores movimientos son calculados siguiendo la ecuación 10. Para ir desde  $i$  a  $j$  se calcula el  $ratio_{ij}$ , donde  $b_{j1}$  y  $b_{j2}$  son los beneficios del punto  $j$  y  $c_{ij}$  es el coste para ir desde  $i$  hasta  $j$ . Por lo tanto, la ecuación 10 relaciona los beneficios con el coste. Cabe destacar que los valores  $b_{j1}$ ,  $b_{j2}$  y  $c_{ij}$  son normalizados para evitar sesgos. Los movimientos con mejor ratio se consideran mejores movimientos.

$$ratio_{ij} = \frac{(b_{j1} + b_{j2})}{c_{ij}}. \quad (10)$$

Después, comenzando por el punto inicial, seleccionamos un movimiento de la lista de 20 movimientos. Este proceso se repite hasta que no se pueden añadir más puntos por la restricción de coste  $C_{max}$ . Indicar que todos los tours finalizan en el punto de fin y que el resto de restricciones son también comprobadas durante la generación aleatoria de una solución.

#### IV-D. Fase Abejas Obreras

Las abejas obreras buscan mejores soluciones, dentro de sus vecindarios. Esto consiste en encontrar una solución vecina y evaluar su calidad. Para obtener soluciones vecinas para las abejas obreras, usamos dos operadores: acortamiento e inserción. El acortamiento intenta reordenar los vértices, dentro de un tour, para minimizar su coste. En este caso usamos el operador de acortamiento 2-opt propuesto por [19]. La inserción comprueba si es factible insertar un nuevo punto después de realizar el acortamiento. Para cada posible inserción, se elige de manera aleatoria uno de los mejores 10 puntos candidatos (según ecuación 10) de los puntos no visitados. Cualquier posible inserción se realiza teniendo en cuenta la restricción de coste  $C_{max}$ . Después de generar la solución vecina, se

compara con la solución actual y si la primera domina a la segunda, entonces se reemplaza la solución actual para la abeja obrera.

#### IV-E. Calcular Cantidad de Néctar

Usamos dos operadores multiobjetivo para determinar cuáles son las mejores soluciones asociadas a las abejas obreras: *rank* y *crowding*. El primero clasifica las soluciones en los diferentes frentes de Pareto acorde a sus relaciones de dominancia, mientras que el segundo tiene en cuenta la distancia de amontonamiento, que consigue variedad en las soluciones. Una explicación más detallada de estos dos operadores puede encontrarse en [20]. Una vez calculados, los combinamos para cada solución en un único valor (llamado fitness multiobjetivo o *MOfitness*), según la ecuación 11. *MOfitness* es un valor importante porque un mayor fitness multiobjetivo implicará una mayor probabilidad de selección, fundamental en la siguiente subsección.

$$MOfitness(x) = \frac{1}{2^{rank(x)} + \frac{1}{1+crowding(x)}}. \quad (11)$$

#### IV-F. Fase Abejas Observadoras

Las abejas obreras comparten la información del fitness de sus soluciones con las abejas observadoras, y estas eligen sus soluciones de manera probabilística basándose en las probabilidades calculadas en base a los valores *MOfitness* (ver ecuación 11). Aplicamos el método de selección de ruleta basado en fitness propuesto por [21]. Por ello, las mejores soluciones reclutarán más abejas observadoras (feedback positivo).

La probabilidad  $p(x^i)$  por la que una solución  $x^i$  es elegida por una abeja observadora se calcula con la ecuación 12.

$$p(x^i) = \frac{MOfitness(x^i)}{\sum_{m=1}^{TP} MOfitness(x^m)}. \quad (12)$$

Después de que una solución  $x^i$  sea probabilísticamente elegida por una abeja observadora, se genera una solución vecina usando dos operadores: intercambio de vértices y acortamiento. Intercambio de vértices intenta reemplazar cada punto existente del tour por un punto no visitado. En cada posición, el punto no visitado se selecciona a través de los mejores 10 puntos (de acuerdo a la ecuación 10) no visitados para esa posición. Después, se usa la misma operación de acortamiento de la subsección IV-D para mejorar la solución.

Tras generar la solución vecina, se compara con la solución original y si la primera no es dominada por la segunda, entonces se reemplaza la solución original para la abeja observadora.

#### IV-G. Fase Abejas Exploradoras

Las abejas obreras y observadoras cuyas soluciones no pueden ser mejoradas después de un número de intentos, indicado por un parámetro de configuración del algoritmo MOABC llamado *limite*, se convierten en abejas exploradoras y sus soluciones son abandonadas. Destacar que MOABC utiliza más abejas exploradoras que el algoritmo ABC original, donde se utiliza

como mucho una por iteración [22]. En MOABC todas las abejas obreras y observadoras con intentos  $\geq \text{limite}$  se convierten en exploradoras. En todo caso, las comparaciones con P-ACO y P-VNS (subsección V-C) son justas ya que se basan en la utilización del mismo tiempo de ejecución. Las abejas exploradoras buscan de manera aleatoria nuevas soluciones (mejorando la exploración del algoritmo). Por lo tanto, aquellas soluciones que no pueden ser mejoradas por explotación, son abandonadas (feedback negativo). La nueva solución asociada a la abeja exploradora se genera aleatoriamente de la misma manera que en la subsección IV-C. Posteriormente, la abeja exploradora intenta mejorar la solución aplicando los tres operadores vistos anteriormente: inserción, intercambio y acortamiento.

#### IV-H. Guardar Soluciones No Dominadas

En cada iteración, las soluciones no dominadas se guardan en un fichero para preservarlas mientras se generan nuevas soluciones. El operador utilizado para calcular las soluciones no dominadas es el *rank*, el cual clasifica las soluciones en diferentes frentes de Pareto de acuerdo a sus relaciones de dominancia. Además se usa el operador *crowding* que junto con el operador *rank* es usado para ordenar las soluciones actuales. Una explicación más detallada de estos operadores puede encontrarse en [20]. Después, las mejores *TP* (tamaño de la población) soluciones son tomadas por las abejas obreras para la siguiente iteración y las soluciones no dominadas (con  $\text{rank} = 0$ ) se guardan en *Fichero\_SND*.

### V. RESULTADOS

Hemos implementado nuestro algoritmo MOABC en C++, con el compilador GNU g++ 4.8.4 en Ubuntu Server 14.04 LTS 64 bits. Todas las ejecuciones se han realizado en un procesador Intel Pentium 4 D de 3,2 GHz y 1 GB de RAM, un entorno computacional muy similar al usado para los algoritmos P-ACO y P-VNS.

#### V-A. Instancias de Comparación

Hemos utilizado las mismas instancias que fueron usadas por [15] y que se encuentran disponibles en <http://prolog.univie.ac.at/research/OP>. Los conjuntos de instancias se pueden categorizar en 10 grupos, de acuerdo al número de vértices. En cada grupo existen varias instancias con distinta restricción de longitud máxima de tour ( $C_{max}$ ). Los primeros 3 grupos (2\_p21, 2\_p32 y 2\_p33) con 21, 32 y 33 vértices, y 11, 18 y 20 instancias respectivamente fueron creados por [1]. Los 2 siguientes grupos (2\_p64 y 2\_p66) con 64 y 66 vértices, y 14 y 26 instancias fueron propuestos por [23]. Estos 5 grupos fueron creados por sus autores con un único objetivo (beneficio), por lo que [15] añadió un segundo objetivo. La distancia entre vértices se calcula usando la fórmula de la distancia Euclídea. Estos 5 grupos pueden considerarse como instancias de test (benchmark).

Los siguientes 5 grupos fueron creados totalmente por [15] y son instancias reales de algunas ciudades y regiones europeas. Dentro de estos 5 grupos tenemos 97 y 273 vértices (2\_p97 y

2\_p273) con 20 instancias cada uno y con una restricción de distancia máxima de tour ( $C_{max}$ ) entre 1 y 20 kilómetros; y 559, 562 y 2143 vértices (2\_p559, 2\_p562 y 2\_p2143) con 29 instancias y una  $C_{max}$  desde 10 hasta 150 kilómetros. Todas estas se proporcionan con una matriz de distancias entre vértices. Además, para estos 5 grupos de instancias se usa una distancia de servicio entre vértices de 0,5 kilómetros que se puede entender como el tiempo necesario para visitar un POI.

#### V-B. Indicadores o Métricas de Calidad

Hemos usado el software disponible en <http://www.tik.ee.ethz.ch/sop/pisa/?page=assessment.php> para calcular los indicadores, según las instrucciones proporcionadas por [24]. Todos los indicadores usados en este trabajo han sido calculados usando valores normalizados de las funciones objetivo. Para algunos indicadores unarios se necesita un conjunto de referencia, por lo que hemos generado un conjunto de referencia con las soluciones no dominadas de todas las ejecuciones de los algoritmos a comparar (MOABC, P-ACO y P-VNS). Hemos usado las soluciones proporcionadas por [15] para cada instancia calculada por los algoritmos P-ACO y P-VNS, y realizado una comparación de acuerdo a varios indicadores o métricas utilizadas habitualmente en la literatura de optimización multiobjetivo: hipervolumen, épsilon unario y R3. Cada uno de estos tres indicadores se basa en diferentes propiedades, lo que permite una evaluación completa y balanceada que incrementa su fiabilidad. Puede encontrarse información detallada sobre los indicadores hipervolumen, épsilon unario y R3 en [25], [26] y [27] respectivamente.

#### V-C. Comparación entre Algoritmos

En esta subsección, comparamos los resultados obtenidos por MOABC con los resultados de los algoritmos P-ACO y P-VNS [15]. Hemos usado el mismo número de ejecuciones independientes que fueron usadas en esos algoritmos, 10 ejecuciones por instancia. También hemos usado los resultados obtenidos por P-ACO y P-VNS en cada instancia, los cuales utilizaron los parámetros de configuración más óptimos, como puede comprobarse en [15]. En el caso de nuestro algoritmo MOABC, siguiendo las recomendaciones de [28], hemos estudiado no solo el parámetro *TP* (tamaño de la población), sino también el parámetro *limite* (criterio de abandono). Después de realizar tests preliminares con un rango de diferentes valores para cada parámetro, hemos establecido la configuración de los parámetros MOABC a un *TP* de 60 y un *limite* de 10. Todos los algoritmos fueron parados tras consumir el mismo tiempo de ejecución, el usado por el algoritmo P-ACO. Los tiempos de ejecución y resultados se encuentran disponibles en <http://prolog.univie.ac.at/research/OP> para todas las ejecuciones e instancias de los algoritmos P-ACO y P-VNS.

En primer lugar, mostramos una comparación de los resultados obtenidos para el indicador hipervolumen ( $I_H$ ). La tabla I muestra los resultados de los tres algoritmos para cada conjunto de instancias.



Tabla I  
RESULTADOS DEL INDICADOR HIPERVOLUMEN. LOS VALORES EN NEGRITA INDICAN SUPERIORIDAD. LOS VALORES ALTOS SON MEJORES.

Conjuntos	$I_H$ (MOABC)	$I_H$ (P-ACO)	$I_H$ (P-VNS)
2_p21	<b>3,525</b>	3,390	3,471
2_p32	3,366	<b>3,375</b>	3,250
2_p33	3,575	<b>3,638</b>	3,615
Media (Pequeño)	<b>3,489</b>	3,468	3,445
2_p64	3,363	<b>3,586</b>	3,569
2_p66	3,346	<b>3,609</b>	3,554
2_p97	<b>3,501</b>	3,315	3,335
Media (Mediano)	3,403	<b>3,503</b>	3,486
2_p273	<b>3,472</b>	3,329	3,320
2_p559	<b>3,648</b>	3,415	3,441
2_p562	<b>3,634</b>	3,451	3,370
2_p2143	<b>3,640</b>	3,144	2,839
Media (Grande)	<b>3,598</b>	3,335	3,242
Media (Todos)	<b>3,497</b>	3,435	3,391

La tabla I muestra la media de los resultados obtenidos por conjunto de instancia. Por ejemplo, el conjunto de instancias 2\_p21 tiene 11 instancias, por lo tanto, esta tabla muestra la media de los resultados de 110 ejecuciones. Además, hemos agrupado los conjuntos de instancias en tres grupos, teniendo en cuenta sus tamaños (número de vértices): pequeño, mediano y grande; y mostrado su media de resultados. Finalmente, mostramos la media para todas las instancias. En instancias pequeñas, MOABC obtiene la mejor media de hipervolumen, y consigue mejores resultados en 2\_p21 que P-ACO y P-VNS. En instancias medianas, el algoritmo MOABC obtiene el mejor hipervolumen para 2\_p97. En instancias grandes, el algoritmo MOABC es definitivamente superior que P-ACO y P-VNS, obteniendo los mejores hipervolumenes para todas las instancias grandes (las más complicadas). De hecho, es aquí donde las diferencias entre los tres algoritmos son mayores, especialmente en el conjunto de instancias con 2143 vértices (2\_p2143). Como conclusión, en la tabla I podemos ver que MOABC tiene la mejor media global de hipervolumen.

Tabla II  
RESULTADOS DEL INDICADOR ÉPSILON UNARIO. LOS VALORES EN NEGRITA INDICAN SUPERIORIDAD. LOS VALORES BAJOS SON MEJORES.

Conjuntos	$I_\epsilon$ (MOABC)	$I_\epsilon$ (P-ACO)	$I_\epsilon$ (P-VNS)
2_p21	<b>1,000</b>	1,108	1,034
2_p32	<b>1,024</b>	1,028	1,124
2_p33	1,074	<b>1,032</b>	1,050
Media (Pequeño)	<b>1,032</b>	1,056	1,069
2_p64	1,085	<b>1,036</b>	1,038
2_p66	1,104	<b>1,033</b>	1,049
2_p97	<b>1,000</b>	1,158	1,137
Media (Mediano)	<b>1,063</b>	1,076	1,074
2_p273	<b>1,072</b>	1,196	1,161
2_p559	<b>1,037</b>	1,118	1,113
2_p562	<b>1,039</b>	1,112	1,128
2_p2143	<b>1,076</b>	1,188	1,265
Media (Grande)	<b>1,056</b>	1,153	1,167
Media (Todos)	<b>1,050</b>	1,095	1,103

En segundo lugar, y usando la misma metodología que en el indicador anterior, la tabla II muestra los resultados para

los tres algoritmos y su comparación basada en el indicador épsilon unario ( $I_\epsilon$ ). En pequeñas instancias, MOABC obtiene la mejor media en el indicador épsilon, y también obtiene mejores resultados para los conjuntos de instancias 2\_p21 y 2\_p32 que P-ACO y P-VNS. En instancias medianas, el algoritmo MOABC nuevamente consigue la mejor media en el indicador épsilon, y también los mejores resultados para 2\_p97. En instancias grandes, MOABC es claramente mejor que P-ACO y P-VNS ya que obtiene los mejores resultados para todos los conjuntos de instancias grandes (las más complejas). Analizando la tabla II podemos observar que MOABC tiene la mejor media global del indicador épsilon, consiguiendo el mejor resultado en 7 de 10 conjuntos de instancias.

Tabla III  
RESULTADOS DEL INDICADOR R3. LOS VALORES EN NEGRITA INDICAN SUPERIORIDAD. LOS VALORES BAJOS SON MEJORES.

Conjuntos	$I_{R3}$ (MOABC)	$I_{R3}$ (P-ACO)	$I_{R3}$ (P-VNS)
2_p21	<b>0,000</b>	0,031	0,010
2_p32	<b>0,003</b>	<b>0,003</b>	0,030
2_p33	0,018	<b>0,005</b>	0,010
Media (Pequeño)	<b>0,007</b>	0,013	0,017
2_p64	0,032	0,011	<b>0,007</b>
2_p66	0,039	<b>0,008</b>	0,011
2_p97	<b>0,000</b>	0,046	0,041
Media (Mediano)	0,024	0,022	<b>0,020</b>
2_p273	<b>0,030</b>	0,067	0,063
2_p559	<b>0,011</b>	0,054	0,048
2_p562	<b>0,010</b>	0,041	0,059
2_p2143	<b>0,038</b>	0,135	0,204
Media (Grande)	<b>0,022</b>	0,074	0,093
Media (Todos)	<b>0,018</b>	0,036	0,043

Finalmente, y usando la misma metodología, la tabla III muestra los resultados para los tres algoritmos y su comparación del indicador R3 ( $I_{R3}$ ). En pequeñas instancias, MOABC obtiene la mejor media del indicador R3, y también los mejores resultados para los conjuntos de instancias 2\_p21 y 2\_p32. En instancias medianas, MOABC consigue los mejores resultados para el conjunto de instancias 2\_p97. En instancias grandes, MOABC es definitivamente mejor que P-ACO y P-VNS, ya que como en los anteriores indicadores consigue los mejores resultados para todas las instancias grandes. Teniendo en cuenta la tabla III, podemos afirmar que MOABC tiene la mejor media global del indicador R3, obteniendo los mejores resultados para 7 de 10 conjuntos de instancias.

Resumiendo los resultados de las tres tablas anteriores podemos concluir que:

- MOABC tiene la mejor media global para los tres indicadores ( $I_H$ ,  $I_\epsilon$  y  $I_{R3}$ ).
- En las instancias pequeñas, MOABC obtiene la mejor media para los tres indicadores, y generalmente, proporciona mejores resultados que P-ACO y P-VNS en 2 de 3 conjuntos de instancias (2\_p21 y 2\_p32).
- En las instancias medianas, de acuerdo con los tres indicadores, MOABC claramente supera a los otros dos algoritmos (P-ACO y P-VNS) en el conjunto de instan-

cias 2\_p97 (uno de los tres conjuntos de instancias del grupo).

- En las instancias grandes, MOABC es el mejor algoritmo, teniendo en cuenta los tres indicadores, sus medias correspondientes, y también los resultados individuales para cada uno de los 4 conjuntos de instancias de este grupo. Las diferencias respecto a los tres algoritmos son especialmente mayores en el último conjunto de instancias con 2143 vértices (el más difícil).

## VI. CONCLUSIONES

Hemos desarrollado un enfoque metaheurístico para solucionar el problema de orientación multiobjetivo. Nuestra propuesta, MOABC, es un algoritmo de optimización multiobjetivo basado en el comportamiento de las abejas melíferas. MOABC ha sido comparado con dos algoritmos multiobjetivo que fueron publicados anteriormente, P-ACO y P-VNS. Las comparaciones fueron realizadas usando instancias de test e instancias del mundo real del problema de orientación, con un total de 216 instancias agrupadas en 10 conjuntos. Utilizamos tres indicadores de calidad multiobjetivo, utilizados habitualmente en la literatura, para comparar los resultados de los tres algoritmos. MOABC es mejor en general que P-ACO y P-VNS, de acuerdo a la media de los indicadores y sensiblemente mejor cuanto mayor (más compleja) es la instancia del problema a resolver (mayor número de vértices). Por lo tanto, podemos concluir que MOABC es una aproximación muy interesante para resolver el problema de orientación.

En el futuro intentaremos aplicar este enfoque a un planificador de rutas turísticas. Además, trataremos de mejorar estos resultados usando otras estrategias distintas (p. ej.: otras variantes de ABC u otros algoritmos evolutivos). Su diseño, implementación y ejecución, y la comparación con algoritmos multiobjetivo es interesante para futuras investigaciones. Finalmente, la aplicación de MOABC en otros tipos de problemas de orientación también supone una línea interesante de trabajo.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por la AEI (Agencia Estatal de Investigación, España) y el FEDER (Fondo Europeo de Desarrollo Regional, UE), bajo el proyecto TIN2016-76259-P (proyecto PROTEIN). Gracias también a la Junta de Extremadura por la ayuda GR18090 otorgada al grupo de investigación TIC015.

## REFERENCIAS

- [1] T. Tsiligirides, Heuristic methods applied to orienteering, *Journal of the Operational Research Society* 35 (9) (1984) 797–809.
- [2] D. Karaboga, B. Basturk, A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm, *Journal of Global Optimization* 39 (3) (2007) 459–471.
- [3] D. Karaboga, B. Gorkemli, C. Ozturk, N. Karaboga, A comprehensive survey: artificial bee colony (ABC) algorithm and applications, *Artificial Intelligence Review* 42 (1) (2014) 21–57.
- [4] Y. Zhang, L. Wu, Optimal multi-level thresholding based on maximum Tsallis entropy via an artificial bee colony approach, *Entropy* 13 (4) (2011) 841–859.
- [5] Y. Zhang, L. Wu, S. Wang, Magnetic resonance brain image classification by an improved artificial bee colony algorithm, *Progress In Electromagnetics Research* 116 (2011) 65–79.
- [6] S. Wang, Y. Zhang, Z. Dong, S. Du, G. Ji, J. Yan, J. Yang, Q. Wang, C. Feng, P. Phillips, Feed-forward neural network optimized by hybridization of PSO and ABC for abnormal brain detection, *International Journal of Imaging Systems and Technology* 25 (2) (2015) 153–164.
- [7] W. Zou, Y. Zhu, H. Chen, B. Zhang, Solving multiobjective optimization problems using artificial bee colony algorithm, *Discrete Dynamics in Nature and Society* 2011 (2011) 569784.
- [8] H. Zhang, Y. Zhu, W. Zou, X. Yan, A hybrid multi-objective artificial bee colony algorithm for burdening optimization of copper strip production, *Applied Mathematical Modelling* 36 (6) (2012) 2578–2591.
- [9] J. Huo, L. Liu, An improved multi-objective artificial bee colony optimization algorithm with regulation operators, *Information* 8 (1) (2017) 18.
- [10] D. Feillet, P. Dejax, M. Gendreau, Traveling salesman problems with profits, *Transportation Science* 39 (2) (2005) 188–205.
- [11] A. Gunawan, H. C. Lau, P. Vansteenwegen, Orienteering problem: A survey of recent variants, solution approaches and applications, *European Journal of Operational Research* 255 (2) (2016) 315–332.
- [12] P. Vansteenwegen, W. Souffriau, D. V. Oudheusden, The orienteering problem: A survey, *European Journal of Operational Research* 209 (1) (2011) 1–10.
- [13] P. Vansteenwegen, W. Souffriau, G. V. Berghe, D. V. Oudheusden, A guided local search metaheuristic for the team orienteering problem, *European Journal of Operational Research* 196 (1) (2009) 118–127.
- [14] I.-M. Chao, B. L. Golden, E. A. Wasil, The team orienteering problem, *European Journal of Operational Research* 88 (3) (1996) 464–474.
- [15] M. Schilde, K. F. Doerner, R. F. Hartl, G. Kiechle, Metaheuristics for the bi-objective orienteering problem, *Swarm Intelligence* 3 (3) (2009) 179–201.
- [16] D. Purevsuren, G. Cui, S. ur Rehman, Evolutionary multiobjective optimization algorithms with path relinking for bi-orienteering problem, in: *Software Engineering and Service Science (ICSESS)*, 2015 6th IEEE International Conference on, 2015, pp. 132–135.
- [17] R. Martí, V. Campos, M. G. Resende, A. Duarte, Multiobjective GRASP with path relinking, *European Journal of Operational Research* 240 (1) (2015) 54–71.
- [18] B. L. Golden, L. Levy, R. Vohra, The orienteering problem, *Naval Research Logistics (NRL)* 34 (3) (1987) 307–318.
- [19] G. A. Croes, A method for solving traveling-salesman problems, *Operations Research* 6 (6) (1958) 791–812.
- [20] K. Deb, A. Pratap, S. Agarwal, T. Meyarivan, A fast and elitist multiobjective genetic algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation* 6 (2) (2002) 182–197.
- [21] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1989.
- [22] M. Mernik, S.-H. Liu, D. Karaboga, M. Črepinšek, On clarifying misconceptions when comparing variants of the Artificial Bee Colony algorithm by offering a new implementation, *Information Sciences* 291 (2015) 115–127.
- [23] I.-M. Chao, B. L. Golden, E. A. Wasil, A fast and effective heuristic for the orienteering problem, *European Journal of Operational Research* 88 (3) (1996) 475–489.
- [24] J. Knowles, L. Thiele, E. Zitzler, A tutorial on the performance assessment of stochastic multiobjective optimizers, Technical report no. 214, Computer Engineering and Networks Laboratory (TIK), ETH Zurich, Switzerland, revised version (Feb 2006).
- [25] N. Beume, C. M. Fonseca, M. López-Ibáñez, L. Paquete, J. Vahrenhold, On the complexity of computing the hypervolume indicator, *IEEE Transactions on Evolutionary Computation* 13 (5) (2009) 1075–1082.
- [26] E. Zitzler, L. Thiele, M. Laumanns, C. M. Fonseca, V. G. da Fonseca, Performance assessment of multiobjective optimizers: an analysis and review, *IEEE Transactions on Evolutionary Computation* 7 (2) (2003) 117–132.
- [27] M. P. Hansen, A. Jaszkiewicz, Evaluating the quality of approximations to the non-dominated set, Tech. Rep. IMM-REP-1998-7, Institute of Mathematical Modelling, Technical University of Denmark (1998).
- [28] N. Veček, S.-H. Liu, M. Črepinšek, M. Mernik, On the importance of the artificial bee colony control parameter ‘limit’, *Information Technology and Control* 46 (4) (2017) 566–604.

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 8.1:  
ALGORITMOS MULTI OBJETIVO  
Y APLICACIONES







# Metaheurísticas híbridas para el problema del apagado de celdas en redes 5G

Pablo H. Zapata-Cano\*, Francisco Luna†, Juan F. Valenzuela-Valdés\*, Antonio M. Mora\*, Pablo Padilla\*

\*Dpto. de Teoría de la Señal, Telemática y Comunicaciones  
CITIC, Universidad de Granada  
pablozapata@correo.ugr.es, {juanvalenzuela, amorag, pablopadilla}@ugr.es

†Dpto. de Lenguajes y Ciencias de la Computación  
Universidad de Málaga  
flv@lcc.uma.es

**Resumen**—La densificación masiva de estaciones base (BS) es una de las tecnologías facilitadoras bien reconocidas por la literatura para el desarrollo de la quinta generación de redes de telecomunicaciones (5G). Su implementación, sin embargo, que requiere el despliegue de miles de BSs por km<sup>2</sup>, está en claro conflicto con uno de los requisitos de diseño de este tipo de redes, que pretende tener un 90 % menos de consumo energético que la actual cuarta generación. Una forma de reducir el coste de estas redes ultradensas consiste en apagar un subconjunto de BSs de forma que minimice su consumo energético pero, a su vez, se maximice la capacidad de la misma. Es, por tanto, un problema de optimización multi-objetivo. En este trabajo se propone un nuevo operador específico para el problema que es capaz de mejorar considerablemente la efectividad de varios algoritmos multiobjetivo. Para ello, se han realizado experimentos con 9 escenarios de diferentes niveles de densificación tanto de BSs como de usuarios que muestran un comportamiento consistente y efectivo independientemente del algoritmo e instancia abordada.

## I. INTRODUCCIÓN

La demanda de tráfico de datos en las redes de telefonía móvil ha crecido de manera constante desde el comienzo de estos sistemas de telecomunicación, y así seguirá haciéndolo en el futuro, según transcurre de diferentes informes tanto de entidades públicas como privadas. En efecto, uno de estos informes recientes elaborado por Ericsson expone que “El tráfico de datos móvil total se espera que crezca a una tasa compuesta anual del 42 %” [1], siendo los smartphones la fuente del 90 % de este tráfico. Para dar servicio a semejante demanda, las diferentes entidades, tanto públicas como privadas, tienen sobre la mesa el desarrollo de la quinta generación de redes de telefonía, la conocida como 5G. De entre las diferentes tecnologías facilitadoras de los sistemas 5G [2], la densificación de la red, i.e., el despliegue de miles de estaciones base (BS) de diferentes tipos por km<sup>2</sup>, permite una mayor reutilización del espectro y, por tanto, incrementar en gran medida la capacidad del sistema. Son las denominadas redes ultra-densas o *Ultra-Dense Networks* (UDNs) [3].

El despliegue de UDNs impone muchas tareas complejas a diferentes niveles de la red (*backhauling*, coordinación de *handovers*, etc.), y se realiza en base a unas estimaciones de

tráfico máximas a las que hay que dar servicio. Esta forma de proceder plantea un serio problema de consumo energético, ya que requiere mantener funcionando ese elevado número de BSs, y es especialmente crítico en periodos de baja demanda de tráfico, donde la red está infrutilizada. Una línea de trabajo prometedora para reducir dicho consumo consiste en, dado un escenario fijo que puede representar a la demanda en un determinado intervalo de tiempo, apagar un subconjunto de las BSs de forma que se minimice la energía por las BSs y, a la vez, mantenga la red operativa maximizando su capacidad [4], [5]. Se trata de un problema de optimización combinatoria NP-completo [6] cuyo espacio de búsqueda crece exponencialmente con el número de BSs de la UDN.

La aproximación en este trabajo, dado los tamaños que previstos para dichas redes, es usar metaheurísticas [7]. En particular, el problema se ha formulado como un problema de optimización multi-objetivo [8] ya que los dos criterios anteriores, consumo *vs.* capacidad, están en conflicto entre sí, puesto que más BSs permiten potencialmente servir a más usuarios o UEs (del inglés, *User Equipments*), pero también se necesita más energía. En un estudio previo [9], se ha abordado el problema utilizando dos metaheurísticas multi-objetivo, una clásica como es NSGA-II [10], y otra relativamente más reciente denominada MOCeII [11]. La contribución del presente trabajo trata de incorporar conocimiento experto del problema en la búsqueda de ambos algoritmos con un operador, denominado CSO (del inglés *Cell Switch Off*), cuyo comportamiento se fundamenta en apagar aquellas BSs que no tienen UEs conectados. Hasta donde conocemos, es la primera vez que se proponer un operador de búsqueda específico para el problema del encendido/apagado de BSs en UDNs. Para mostrar su efectividad, se ha incorporado al ciclo evolutivo de NSGA-II y MOCeII, dando lugar a sus versiones híbridas NSGA-II<sub>CSO</sub> y MOCeII<sub>CSO</sub>, y se han comparado a las versiones canónicas de los algoritmos sobre un conjunto de 9 escenarios diferentes que utilizan una densificación creciente tanto en BSs como en UEs. Los resultados han mostrado que se trata de un operador que permite mejorar considerablemente la búsqueda de ambas metaheurísticas multi-objetivo.

Tabla I: Parámetros del modelo para BSs y UEs

Celda	Parámetro	LL	LM	LH	ML	MM	MH	HL	HM	HH
macro	$G_{tx}$	14								
	$f$	2 GHz (BW = 100 MHz)								
micro1	$G_{tx}$	12								
	$f$	3.5 GHz (BW = 175 MHz)								
	$\lambda_P^{macro1}$ [BS/km <sup>2</sup> ]	100	100	100	200	200	200	300	300	300
micro2	$G_{tx}$	10								
	$f$	5 GHz (BW = 250 MHz)								
	$\lambda_P^{micro2}$ [BS/km <sup>2</sup> ]	100	100	100	200	200	200	300	300	300
pico1	$G_{tx}$	5								
	$f$	10 GHz (BW = 500 MHz)								
	$\lambda_P^{pico1}$ [BS/km <sup>2</sup> ]	500	500	500	600	600	600	700	700	700
pico2	$G_{tx}$	7								
	$f$	14 GHz (BW = 700 MHz)								
	$\lambda_P^{pico2}$ [BS/km <sup>2</sup> ]	500	500	500	600	600	600	700	700	700
femto1	$G_{tx}$	4								
	$f$	28 GHz (BW = 1400 MHz)								
	$\lambda_P^{femto1}$ [BS/km <sup>2</sup> ]	1000	1000	1000	2000	2000	2000	3000	3000	3000
femto2	$G_{tx}$	3								
	$f$	66 GHz (BW = 3300 MHz)								
	$\lambda_P^{femto2}$ [BS/km <sup>2</sup> ]	1000	1000	1000	2000	2000	2000	3000	3000	3000
UEs	$\lambda_{UE}^{UE}$ [UE/km <sup>2</sup> ]	1000	1000	1000	2000	2000	2000	3000	3000	3000

El resto del trabajo se organiza como sigue: la siguiente sección detalla el modelado de las UDNs y el cálculo de las funciones objetivo. La Sección III describe el operador CSO y su integración en los ciclos evolutivos de NSGA-II y MOCeCell. La metodología de los experimentos y el análisis de resultados se realiza en la Sección IV. Por último, la Sección V incluye las principales conclusiones del trabajo y las líneas de trabajo futuro que se abren a partir de él.

## II. MODELADO DEL PROBLEMA

Esta sección se dedica a la descripción del modelo de UDN utilizado. Se considera un área de servicio de  $500 \times 500$  m<sup>2</sup>, que se ha discretizado utilizando una malla de  $100 \times 100$  puntos (también llamados “pixels” o elementos de área) distribuidos uniformemente y, por tanto, cada uno cubre un área de 25 m<sup>2</sup> donde la potencia de la señal se asume constante. La UDN está dividida en 10 regiones diferentes, cada una con unas condiciones de propagación diferentes.

Para calcular la potencia de señal recibida en cada punto,  $P_{rx}$  [dBm], se ha utilizado el siguiente esquema:

$$P_{rx}[\text{dBm}] = P_{tx}[\text{dBm}] + P_{Loss}[\text{dB}] \quad (1)$$

donde  $P_{rx}$  es la potencia recibida en dBm,  $P_{tx}$  es la potencia transmitida en dBm, y  $P_{Loss}$  son las pérdidas globales de señal, que depende de las condiciones de propagación de cada región, y se calcula como:

$$P_{Loss}[\text{dB}] = GA + PA \quad (2)$$

siendo  $GA$  las ganancias de las dos antenas (transmisión y recepción), y  $PA$  las pérdidas de transmisión en el espacio, calculadas como:

$$PA[\text{dB}] = \left( \frac{\lambda}{2 * \pi * d} \right)^K \quad (3)$$

donde  $d$  es la distancia Euclídea del punto correspondiente a la BS,  $K$  es el exponente de pérdidas, que varía aleatoriamente

en el intervalo [2.0, 4.0] para cada una de las 10 regiones. El ratio señal-interferencia más ruido (*Signal to Interference plus Noise Ratio* o SINR) para el UE  $k$ , se calcula como:

$$SINR_k = \frac{P_{rx,j,k}[\text{mW}]}{\sum_{i=1}^M P_{rx,i,k}[\text{mW}] - P_{rx,j,k}[\text{mW}] + P_n[\text{mW}]} \quad (4)$$

donde  $P_{rx,j,k}$  es la potencia recibida por el UE  $k$  de la BS  $j$ , el sumatorio es la potencia total recibida por el UE  $k$  desde todas las BSs activas y operando a la misma frecuencia que  $j$ , y  $P_n$  es la potencia del ruido, calculada como:

$$P_n = -174 + 10 \log_{10} BW_j \quad (5)$$

siendo  $BW_j$  el ancho de banda de la BS  $j$ , definida como el 5% de la frecuencia de operación de la BS. La Tabla I incluye todos los valores para los parámetros del modelo. Finalmente, la capacidad del UE  $k$  es:

$$C_k[\text{bps}] = BW_k^j[\text{Hz}] * \log_2(1 + SINR_k) \quad (6)$$

donde  $BW_k^j$  es el ancho de banda asignado al UE  $k$  cuando se conecta a la BS  $j$ , asumiendo una planificación en round-robin, esto es:

$$BW_k^j = \frac{BW_j}{N_j} \quad (7)$$

considerando  $N_j$  como el número de UEs conectados a la BS  $j$ . La política de asignación de UEs a BSs es que un UE siempre es servido por la BS con mayor SINR, independientemente del tipo de BS.

El modelo de UDN usado en este trabajo utiliza 4 tipos de celdas que tienen diferentes tamaños (i.e., zonas de cobertura). Ordenadas según su tamaño, tenemos femtoceldas, picoceldas, microceldas y macroceldas. De los tres primeros tipos, además, se han definido dos subtipos (ver Tabla I), con lo que suman un total de 7 tipos de celdas diferentes. Las BSs que sirven a dichas celdas tienen todas una potencia de transmisión  $P_{tx} = 750$  mW, por lo que su cobertura real está definida por sus



frecuencias de operación y las consiguientes pérdidas que se inducen en el cálculo de la SINR (a mayor frecuencia, menor cobertura).

Las BSs se despliegan utilizando un Proceso de Poisson (PPP) independiente con diferentes densidades (definidas por  $\lambda_P^{BS}$ ). Los UEs también se posicionan usando una PPP con valor  $\lambda_P^{UE}$ , pero utilizando atractores sociales (SAs por sus siglas en inglés), siguiendo el procedimiento propuesto en [12]. Este esquema de despliegue usa, además, dos factores  $\alpha$  and  $\mu_\beta$ , que indican cómo de fuerte es la atracción de BSs a SAs, y de SAs a UEs. Los valores usados en las simulaciones son  $\alpha = \mu_\beta = 0.25$ .

La parametrización detallada de los 9 escenarios abordados en este trabajo se incluye en la Tabla I. Los nombres en las nueve últimas columnas, XY, indican la densidad del despliegue de BSs y UEs, respectivamente, de forma que X,Y = {L,M,H} significa un despliegue de baja (L), media (M) o alta (H) densidad para BSs (parámetro  $\lambda_P^{BS}$  del PPP) y UEs (parámetro  $\lambda_P^{UE}$  del PPP). Los parámetros  $G_{tx}$  y  $f$  de cada tipo de celda se refieren a la ganancia en transmisión y la frecuencia de operación de la BS, respectivamente.

El cálculo de las funciones objetivo se realiza como sigue. Para el primer objetivo, que mide el consumo eléctrico, cuenta el número de BSs que están activas en la solución candidata de la metaheurística. Se asume que, una vez encendidas sólo se considera la potencia de transmisión, que tiene valor  $P_{tx} = 750mW$  para todos los tipos. Para calcular la capacidad total del sistema, como medida de la cantidad de información que pueden recibir (downlink) los UEs presentes en la UDN, se usa el siguiente procedimiento: primero, los UEs se asignan a las BSs que les proporcionan mejor SINR; segundo, el ancho de banda disponible en la BS se reparte entre los UEs conectados; y, finalmente, se calcula la capacidad para cada uno de ellos según la Ecuación 6 y se agrega la de todos.

### III. METAHEURÍSTICAS HÍBRIDAS: EL OPERADOR CSO

En esta sección se detalla, en primer lugar, la representación utilizada para abordar el problema y los consiguientes operadores genéticos, en segundo lugar, el operador CSO, la contribución de este trabajo, y, finalmente, una breve descripción de las metaheurísticas multi-objetivo utilizadas y cómo integran al operador dentro de su ciclo evolutivo.

#### III-A. Representación y operadores genéticos

La representación utilizada para las soluciones candidatas es el clásico array de bits en el que cada bit representa a una celda de la UDN e indica si está encendida ('1') o apagada ('0'). Los operadores de selección, cruce y mutación son, respectivamente, torneo binario, cruce de dos puntos con  $c_r = 0.9$ , y bit flip con  $m_r = 1/L$ , donde  $L$  es el número de BSs de la UDN. La condición de parada consiste en computar 100000 evaluaciones de función. Todos los algoritmos de este trabajo comparten la implementación tanto la representación de soluciones, como de los operadores, ya que están integrados en el framework para optimización multiobjetivo jMetal<sup>1</sup>.

<sup>1</sup><https://github.com/jMetal/>

#### Algoritmo 1 Pseudocódigo del operador CSO

```

1:  $C \leftarrow \text{celdas}(UDN)$ 
2: for  $c$  in  $C$  do
3:   if (UEsConectados( $c$ ) == 0) then
4:     apagar( $c$ )
5:   end if
6: end for

```

#### III-B. El operador CSO

Para incorporar información del problema a la búsqueda de las metaheurísticas, el operador CSO recorre todas las celdas de la solución candidata, y apaga aquellas que no están sirviendo a ningún UE.

Su aparente simpleza no impide que sea un operador con gran capacidad de intensificación de la búsqueda y, como se verá más adelante en la sección experimental, se ha de aplicar con precaución. Hay que tener en cuenta que si, en cada solución candidata, se apagan todas las celdas que no tienen usuarios conectados, se impide que el algoritmo pueda evolucionar soluciones que reasignen UEs de una BS a otra vacía, puesto que todas estarían apagadas al aplicar el operador.

#### III-C. Los algoritmos híbridos NSGA-II<sub>CSO</sub> y MOCeII<sub>CSO</sub>

Esta sección se articula en base a la plantilla genérica de metaheurística multiobjetivo (Algoritmo 2) a partir de la cual se describen las versiones canónicas de NSGA-II y MOCeII para, posteriormente, detallar los cambios necesarios para introducir el operador CSO.

El algoritmo NSGA-II (*Non-dominated Sorting Genetic Algorithm II* por sus siglas en inglés) fue propuesto por Deb *et al.* en [10]. Se trata de un algoritmo genético cuyo funcionamiento se basa en generar, a partir de una población  $P_t$ , otra auxiliar  $Q_t$  usando los operadores genéticos de selección, cruce y mutación (línea 8 del Algoritmo 2); entonces, las soluciones incluidas en  $P_t \cup Q_t$  se ordenan según su rango y, aquellas con mejor valor de este indicador de calidad, con las que pasan a la siguiente generación  $P_{t+1}$  (línea 11). En caso de tener que seleccionar entre individuos de mismo rango, NSGA-II utiliza

#### Algoritmo 2 Plantilla de una metaheurística multi-objetivo

```

1:  $S(0) \leftarrow \text{GenerarSolucionesIniciales}()$ 
2:  $A(0) \leftarrow \emptyset$ 
3: Evaluar( $S$ )
4:  $A(0) \leftarrow \text{Actualizar}(A(0), S(0))$ 
5:  $t \leftarrow 0$ 
6: while not CondiciónDeParada() do
7:    $t \leftarrow t + 1$ 
8:    $S(t) \leftarrow \text{OperadoresGenéticos}(A(t-1), S(t-1))$ 
9:   Evaluar( $S'(t)$ )
10:   $A(t) \leftarrow \text{Actualizar}(A(t), S'(t))$ 
11: end while
12: Salida:  $A$ 

```

**Algoritmo 3** NSGA-II<sub>CSO</sub> y MOCeII<sub>CSO</sub>

- 
- 8:  $S(t) \leftarrow \text{OperadoresGenéticos}(A(t-1), S(t-1))$
  - 9:  $S'(t) \leftarrow \text{CSO}(S(t))$
  - 10: Evaluar( $S'(t)$ )
  - 11:  $A(t) \leftarrow \text{Actualizar}(A(t), S'(t))$
- 

un estimador de densidad que prioriza aquellas que están en las zonas menos pobladas de la aproximación al frente.

Por su parte, MOCeII (*Multi-Objective Cellular Genetic Algorithm* por sus siglas en inglés) es un algoritmo genético celular propuesto en [11]. Como muchas otras metaheurísticas multi-objetivo, MOCeII incluye un archivo externo para almacenar las soluciones no-dominadas que encuentra durante su ejecución (línea 4 del Algoritmo 2). Este archivo está acotado y usa el mismo estimador de densidad de NSGA-II para mantener la diversidad en su aproximación al frente de Pareto. Su diferencia fundamental radica en la relación de vecindad entre las soluciones, que se disponen en una malla toroidal 2D. El operador de selección escoge una solución de dicho vecindario y otra desde el archivo externo. Después de aplicar los operadores de cruce y mutación, el nuevo individuo generado se compara con el actual y lo reemplaza si es mejor; si ambas soluciones son no-dominadas, MOCeII reemplaza el peor individuo del vecindario. En estos dos últimos casos, el nuevo individuo se añade al archivo externo.

La integración del operador CSO dentro del ciclo evolutivo de NSGA-II y MOCeII se consigue reemplazando las líneas 8 a 10 del Algoritmo 2 por las líneas del algoritmo Algoritmo 3, es decir, justo después de aplicar los operadores genéticos, y antes de evaluar para determinar su incorporación o no a la siguiente generación de soluciones del algoritmo. Esto permite apagar aquellas celdas que no está sirviendo a ningún UE. Su aplicación, como el cruce y la mutación, depende de una tasa de aplicación,  $csor$ , sobre la que se han diseñado diferentes experimentos para ver su impacto.

#### IV. EXPERIMENTACIÓN

Esta sección describe la metodología utilizada para la realización de los experimentos que muestran la efectividad de las nuevas propuestas híbridas, NSGA-II<sub>CSO</sub> y MOCeII<sub>CSO</sub>, así como el análisis de los resultados obtenidos.

##### IV-A. Metodología

Dado que las metaheurísticas son algoritmos estocásticos, se han realizado 30 ejecuciones independientes para cada algoritmo en cada uno de los nueve escenarios. Cada ejecución genera una instancia aleatoria del problema, pero se usan las mismas 30 semillas para garantizar que todos los algoritmos abordan el mismo conjunto de instancias. Se han utilizado dos indicadores para medir la calidad de las aproximaciones al frente de Pareto alcanzadas por los cuatro algoritmos: el hypervolume (HV) [13] y las superficies de consecución (del inglés *attainment surfaces*) [14].

El HV está considerado como uno de los indicadores más fiables dentro de la comunidad multi-objetivo. Es un indicador

a maximizar cuyos valores dependen de la escala arbitraria de los valores de las funciones objetivo. Para su uso correcto, en caso de no disponer del frente óptimo de Pareto, se genera un frente de referencia (RPF) para cada instancia del problema, compuesto por todas las soluciones no dominadas encontradas por todos los algoritmos para el mismo. Con ese RPF, se normaliza cada aproximación al frente antes de calcular el valor del HV. Para dotar a estos resultados de confianza estadística, se ha comprobado primero la normalidad (test de Kolmogorov-Smirnov) y homocedasticidad (Test de Levene) de las muestras y, una vez verificadas ambas condiciones, se ha usado un test paramétrico (test one-way ANOVA) para verificar si se rechaza la hipótesis nula. Por último, se ha aplicado el test de Tukey para realizar la comparación por pares. En todos los casos se ha utilizado un nivel de confianza del 95 %.

Si bien el HV permite comparar varios algoritmos numéricamente, desde el punto de vista del experto que ha de elegir una solución del frente, este indicador no da información sobre la forma en la que se distribuyen las soluciones no-dominadas a lo largo de las diferentes aproximaciones al frente de Pareto. Las *attainment surfaces* tienen precisamente esa funcionalidad. Son una representación gráfica del rendimiento esperado y su variabilidad de diferentes ejecuciones de un algoritmo multi-objetivo. Informalmente, la 50 %-attainment surface se podría considerar como la aproximación promedio al frente de Pareto, es decir, sería el equivalente a la mediana en el caso mono-objetivo.

##### IV-B. Resultados

Se ha planteado un diseño experimental para medir el efecto de la hibridación entre NSGA-II y MOCeII, y el operador CSO. Para ello, se han planteado dos tasas de aplicación de este último: 0.01 y 0.1, que se han usado como superíndice en el nombre para distinguirlos. Así, se puede ver que, por cada algoritmo, hay tres columnas: su versión canónica y las versiones híbridas con tasa de aplicación de 0.01 y 0.1. En la Tabla II, que incluye los resultados del HV, usa un fondo en gris los mejores valores de este indicador por cada algoritmo.

Hay una primera conclusión clara: la hibridación mejora la búsqueda de los algoritmos, ya que, en ningún escenario, un algoritmo canónico ha sido mejor que uno híbrido. Esto es un resultado muy prometedor porque existen pocas aproximaciones híbridas en el dominio y es un terreno amplísimo por explorar. La segunda es que, entre las versiones híbridas, aquellas que usan una tasa de aplicación más pequeña (0.01 vs. 0.1) permiten alcanzar mejores aproximaciones al frente de Pareto. Después de inspeccionar trazas de las ejecuciones (no incluidas por falta de espacio), se puede observar que el operador tiene un gran efecto en la diversidad de la población, es decir, si se aplica con mucha frecuencia, termina apagando en gran medida las mismas celdas y cercena el nuevo material genético creado por los operadores de cruce y mutación.

Si nos detenemos un poco más en los números concretos y se analizan según las instancias, se puede observar que las diferencias en el HV se hace más manifiesta a medida que



Tabla II: Resultados del HV para todos los algoritmos sobre los 9 escenarios

	NSGA-II	NSGA-II <sup>0.01</sup> <sub>CSO</sub>	NSGA-II <sup>0.1</sup> <sub>CSO</sub>	MOCcell	MOCcell <sup>0.01</sup> <sub>CSO</sub>	MOCcell <sup>0.1</sup> <sub>CSO</sub>
<i>LL</i>	0.4560 ±0.1017	0.5372 ±0.1263	0.5296 ±0.1250	0.4737 ±0.1180	0.5359 ±0.1250	0.5329 ±0.1274
<i>LM</i>	0.4364 ±0.0929	0.5404 ±0.1141	0.5338 ±0.1179	0.4155 ±0.0928	0.5385 ±0.1155	0.5351 ±0.1145
<i>LH</i>	0.4548 ±0.1027	0.5408 ±0.1274	0.5371 ±0.1271	0.4324 ±0.0903	0.5340 ±0.1252	0.5371 ±0.1248
<i>ML</i>	0.3288 ±0.0698	0.4907 ±0.1045	0.4853 ±0.1045	0.3584 ±0.0817	0.4892 ±0.1059	0.4867 ±0.1032
<i>MM</i>	0.3904 ±0.0728	0.5573 ±0.1095	0.5455 ±0.1045	0.3947 ±0.0728	0.5554 ±0.1061	0.5508 ±0.1044
<i>MH</i>	0.3243 ±0.0580	0.5356 ±0.0948	0.5401 ±0.0874	0.3194 ±0.0650	0.5235 ±0.0925	0.5565 ±0.0954
<i>HL</i>	0.1316 ±0.0798	0.5117 ±0.1071	0.4981 ±0.1093	0.2681 ±0.0729	0.5142 ±0.1076	0.5051 ±0.1093
<i>HM</i>	0.1103 ±0.0706	0.4837 ±0.0921	0.4714 ±0.0900	0.2157 ±0.0679	0.4790 ±0.0920	0.4743 ±0.0903
<i>HH</i>	0.1518 ±0.0681	0.4852 ±0.0905	0.4717 ±0.0917	0.2335 ±0.0619	0.4774 ±0.0863	0.4690 ±0.0880

umenta la densidad tanto de BSs como de UEs. Es decir, a medida que las instancias se hacen más grandes y complejas, el efecto del operador es mucho más determinante. Esto es además consistente para ambos algoritmos, ya que NSGA-II y MOCcell tienen unos promedios de HV de 0.1313 y 0.2390 en las instancias HX, respectivamente, cuando las versiones híbridas están en torno a 0.4935 y 0.4902.

Un último efecto del operador CSO sobre los algoritmos es que reduce e incluso invierte las mejoras en la búsqueda existentes entre NSGA-II y MOCcell. Con esto nos referimos a que, tanto en el trabajo previo [9], como en los valores del HV alcanzados por los algoritmos canónicos, MOCcell supera claramente a NSGA-II. Sin embargo, cuando se usa el operador CSO, la situación se invierte, y es NSGA-II el que obtiene valores más altos de este indicador. Las diferencias son mínimas y estadísticamente no significativas según el test de Tukey, pero viene a poner de manifiesto que el motor de búsqueda de NSGA-II ha integrado mejor el operador CSO.

La corroboración gráfica de lo que muestra el HV se puede observar en las attainment surfaces (Fig. 1). A medida que los escenarios son más densos, las aproximaciones medianas al frente de las versiones canónicas se van separando cada vez más de las versiones híbridas. Sin embargo, se aprecia un efecto que el HV oculta, y de ahí la importancia de tener representaciones gráficas de los frentes obtenidos: las versiones híbridas muestrean mucho más las zonas del espacio de búsqueda que contienen pocas BSs activas (áreas más hacia la izquierda), pero las versiones canónicas obtienen soluciones no-dominadas con muchas BSs operativas (mayor consumo), pero también de mayor capacidad (áreas más a la izquierda). Esto está provocado porque el operador CSO, en realidad, sólo mejora uno de los objetivos (consumo), descuidando el otro (capacidad).

## V. CONCLUSIONES

Este trabajo se ha planteado la resolución del apagado de celdas en el contexto de los despliegues ultradensos de

estaciones base que serán necesarios para la quinta generación de sistemas de telecomunicación. Se ha formulado como un problema de optimización multi-objetivo en el que se ha de minimizar el consumo (número de BSs activas), a la vez que se ha de aumentar la capacidad (GBps en *downlink*). Se ha propuesto un nuevo operador de búsqueda local, llamado CSO, que se ha integrado dentro de dos algoritmos del dominio, uno muy bien conocido, NSGA-II, y otro más reciente, pero que ha resultado en una mejor exploración del espacio de búsqueda, denominado MOCcell. Las versiones híbridas, NSGA-II<sub>CSO</sub> y MOCcell<sub>CSO</sub>, han alcanzado aproximaciones al frente de Pareto del problema con una mejora notable en el indicador HV, si bien las attainment surfaces han mostrado que el operado ha centrado la búsqueda en zonas con UDNs que activan un bajo número de BSs, y también de menor capacidad. Como trabajo futuro se pretende seguir diseñando operadores de búsqueda que equilibren ambos objetivos, así como el impacto de los mismos en otras metaheurísticas multi-objetivo del dominio.

## RECONOCIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Economía y Competitividad y los fondos FEDER con los proyectos TIN2016-75097-P, TIN2014-56494-C4-3-P, TIN2017-85727-C4-2-P y TEC2015-68752. Francisco Luna también agradece la ayuda de la Universidad de Málaga y el proyecto PPIT.UMA.B12017/15 del I Plan Propio de Investigación y Transferencia.

## REFERENCIAS

- [1] Ericsson, "Mobility Report," *White Paper*, no. June, 2017. [Online]. Available: <https://www.ericsson.com/assets/local/mobility-report/documents/2017/ericsson-mobility-report-june-2017.pdf>
- [2] D. Lopez-Perez, M. Ding, H. Claussen, and A. H. Jafari, "Towards 1 Gbps/UE in Cellular Systems: Understanding Ultra-Dense Small Cell Deployments," *IEEE Communications Surveys & Tutorials*, vol. 17, no. 4, pp. 2078–2101, 2015.
- [3] X. Ge, S. Tu, G. Mao, C.-X. Wang, and T. Han, "5G Ultra-Dense Cellular Networks," *IEEE Wireless Communications*, vol. 23, no. 1, pp. 72–79, feb 2016.

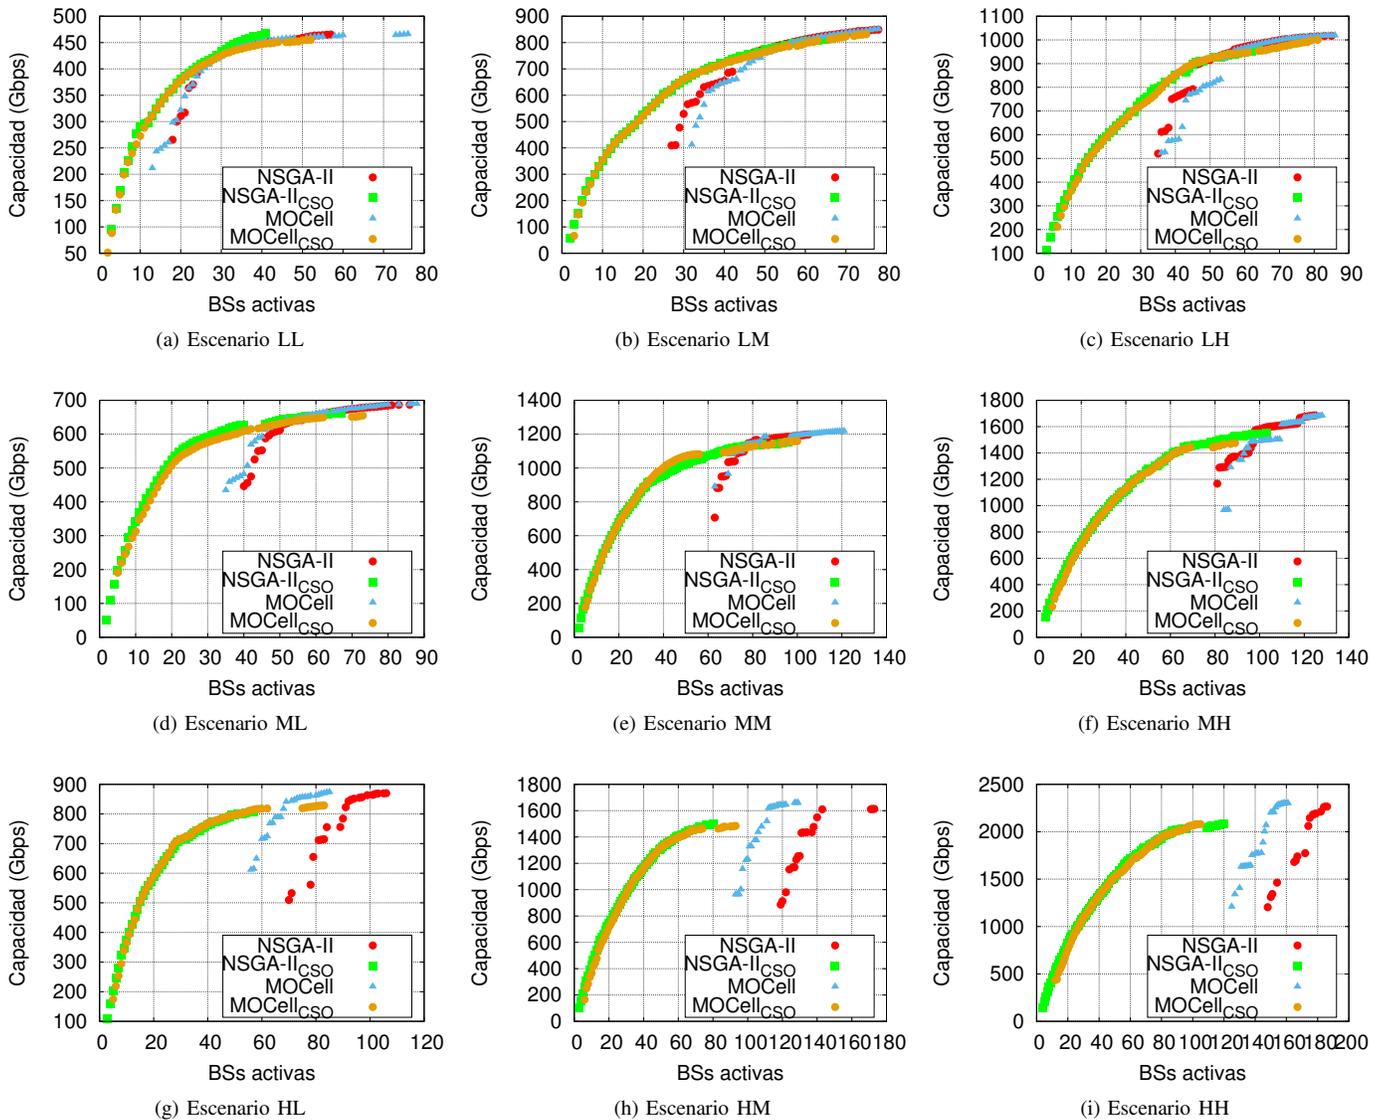


Figura 1: Attainment surfaces de NSGA-II, MOCeII y sus versiones híbridas, NSGA-II<sub>CSO</sub> y MOCeII<sub>CSO</sub>, para los 9 escenarios considerados

- [4] Q.-N. Le-The, T. Beitelmal, F. Lagum, S. S. Szyszkowicz, and H. Yanikomeroglu, "Cell Switch-Off Algorithms for Spatially Irregular Base Station Deployments," *IEEE Wireless Communications Letters*, vol. 6, no. 3, pp. 354–357, jun 2017.
- [5] F. Lagum, Q.-N. Le-The, T. Beitelmal, S. S. Szyszkowicz, and H. Yanikomeroglu, "Cell Switch-Off for Networks Deployed With Variable Spatial Regularity," *IEEE Wireless Communications Letters*, vol. 6, no. 2, pp. 234–237, apr 2017.
- [6] D. Gonzalez G., J. Hamalainen, H. Yanikomeroglu, M. Garcia-Lozano, and G. Senarath, "A Novel Multiobjective Cell Switch-Off Framework for Cellular Networks," *IEEE Access*, vol. 4, pp. 7883–7898, 2016.
- [7] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: Overview and conceptual comparison," *ACM Computing Surveys*, vol. 35, no. 3, pp. 268–308, 2003.
- [8] D. Gonzalez Gonzalez, E. Mutafungwa, B. Haile, J. Hämäläinen, and H. Poveda, "A Planning and Optimization Framework for Ultra Dense Cellular Deployments," *Mobile Information Systems*, vol. 2017, pp. 1–17, 2017.
- [9] F. Luna, J. F. Valenzuela-Valdés, R. Luque-Baena, J. M. Cruz, and P. Padilla, "Addressing the 5g cell switch-off problem with a multi-objective cellular genetic algorithm," in *IEEE 5G World Forum, 9-11 July, Santa Clara, USA*, 2018, pp. 422–426.
- [10] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182 – 197, 2002.
- [11] A. J. Nebro, J. J. Durillo, F. Luna, B. Dorronsoro, and E. Alba, "Mocell: A cellular genetic algorithm for multiobjective optimization," *Int. J. of Intelligent Systems*, vol. 24, no. 7, pp. 723 – 725, 2009.
- [12] M. Mirahsan, R. Schoenen, and H. Yanikomeroglu, "HetHetNets: Heterogeneous Traffic Distribution in Heterogeneous Wireless Cellular Networks," *IEEE Journal on Selected Areas in Communications*, vol. 33, no. 10, pp. 2252–2265, 2015.
- [13] E. Zitzler and L. Thiele, "Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach," *IEEE Trans. Evolutionary Computation*, vol. 3, no. 4, pp. 257–271, 1999.
- [14] J. Knowles, "A summary-attainment-surface plotting method for visualizing the performance of stochastic multiobjective optimizers," in *5th International Conference on Intelligent Systems Design and Applications (ISDA'05)*, 2005, pp. 552 – 557.



# MOEA-EFEP: Un algoritmo evolutivo multi-objetivo para la extracción de patrones emergentes difusos

A.M. García-Vico, C.J. Carmona, P. González, M.J. del Jesus

*Departamento de Informática, Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence*

*Universidad de Jaén, Jaén, España*

{agvico|ccarmona|pglez|mjjesus}@ujaen.es

**Resumen**—Este trabajo es un resumen del publicado por los autores en la revista *IEEE Transactions on Fuzzy Systems* [1] en el que se presenta un nuevo modelo evolutivo multi-objetivo para la extracción de patrones emergentes difusos con un gran balance entre la capacidad descriptiva de los mismos y su fiabilidad.

**Index Terms**—Descubrimiento de reglas descriptivas supervisadas, minería de patrones emergentes, algoritmos evolutivos multi-objetivo, sistemas difusos evolutivos.

## I. RESUMEN

Tradicionalmente, en minería de datos se distinguen dos enfoques claramente diferenciados: un enfoque predictivo, cuyo objetivo es la obtención de un modelo para la predicción del valor de una variable de interés en nuevas instancias no vistas hasta el momento, utilizando para ello aprendizaje supervisado; y un enfoque descriptivo con el objetivo de crear un modelo que describa relaciones interesantes en los datos utilizando para ello habitualmente aprendizaje no supervisado. Sin embargo, a lo largo de la literatura se han ido desarrollando una serie de técnicas que se encuentran a medio camino entre ambos enfoques, agrupadas bajo el nombre de “descubrimiento de reglas descriptivas basadas en aprendizaje supervisado” (SDRD) [2], [3] cuyo propósito es la obtención de un modelo descriptivo con de conocimiento relevante sobre una variable de interés en un conjunto de datos.

El principal objetivo de las técnicas SDRD no es la extracción de un modelo con el fin de clasificar nuevas instancias, sino la obtención de un modelo que permita describir de una manera simple y fácilmente comprensible el fenómeno subyacente en los datos por parte de los expertos. Por tanto, en este grupo de tareas se agrupan todas aquellas técnicas de minería de datos que utilizan un modelo de reglas y aprendizaje supervisado para obtener conocimiento descriptivo sobre los datos, como por ejemplo el descubrimiento de subgrupos [4], [5], la minería de conjuntos de contraste [6] o la minería de patrones emergentes [7], [8], entre otras.

La minería de patrones emergentes (EPM) se define como la búsqueda de todos los patrones que, dados dos conjuntos de datos  $D_1$  y  $D_2$ , tengan un índice de crecimiento (GR) mayor a un umbral  $\rho > 1$ . Este índice de crecimiento se define como la siguiente función:

$$GR(X) = \begin{cases} 0, & \text{Si } Sop_1(X) = Sop_2(X) = 0, \\ \infty, & \text{Si } Sop_1(X) = 0 \wedge Sop_2(X) \neq 0, \\ \frac{Sop_2(X)}{Sop_1(X)}, & \text{en otro caso} \end{cases} \quad (1)$$

donde  $Sop_i(X)$  indica el soporte del patrón  $X$  en el conjunto de datos  $i$ . EPM tiene como objetivos principales la descripción de características discriminativas entre clases, la descripción de fenómenos emergentes en datos temporales, donde el primero de estos objetivos ha sido el más desarrollado a lo largo de la literatura.

El principal problema de la extracción de patrones emergentes reside en su propia definición, ya que definen un espacio de búsqueda que no es convexo debido a que el GR es una proporción de soportes [9]. Esto permite que aquellos patrones con soportes más altos puedan tener un GR menor que aquellos patrones con soportes menores. Por esta razón a lo largo de la literatura se han desarrollado diferentes tipos de patrones emergentes, como por ejemplo los patrones emergentes *Jumping* [10] o los patrones emergentes  $\chi^2$  [11]. Asimismo, se han desarrollado diferentes técnicas de extracción como las técnicas basadas en límites o en árboles con el objetivo de extraer de manera eficiente aquellos de mayor calidad y poder discriminativo. Sin embargo, la gran mayoría de estos métodos han sido completamente enfocados a clasificación ignorando por completo las capacidades descriptivas de los mismos. No obstante, en los últimos años se han desarrollado técnicas basadas en algoritmos evolutivos que han permitido la extracción de patrones emergentes con un buen balance entre las capacidades descriptivas y la fiabilidad de las mismas [8].

Nuestra aportación a la literatura es un algoritmo genético multi-objetivo que permite la extracción de patrones emergentes difusos llamado MOEA-EFEP (*Multi-Objective Evolutionary Algorithm for the Extraction of Fuzzy Emerging Patterns*). MOEA-EFEP utiliza lógica difusa para el tratamiento de variables de tipo numérico con el fin de evitar pérdidas de información y mejorar la interpretabilidad de los resultados. Asimismo, MOEA-EFEP está basado en el algoritmo multi-objetivo NSGA-II [12], el cual ha sido modificado para que el proceso de búsqueda esté orientado a la extracción de patrones

emergentes de gran calidad, es decir, un conjunto de patrones simple, con gran capacidad de generalización y fiable.

En concreto, MOEA-EFEP emplea un enfoque “cromosoma = regla” en el que un individuo de la población representa una regla potencial y el resultado final es el conjunto formado por la unión de varios individuos. En este punto, es importante remarcar que MOEA-EFEP representa tanto el antecedente como el consecuente de la regla por lo que puede extraer patrones emergentes para todas las clases del problema en una única ejecución. Asimismo, se permite el uso de dos representaciones del conocimiento diferentes en función de las necesidades del problema: reglas canónicas, formadas por conjunciones de pares atributo-valor o bien reglas en forma normal disyuntiva (DNF) donde se permite que un atributo pueda tener más de un posible valor mediante disyunciones.

Los individuos de la población interactúan entre sí mediante el uso de un enfoque cooperativo-competitivo. Este enfoque se basa, por un lado, en la competición propia de un algoritmo evolutivo a través de los operadores genéticos. Dichos operadores son, en concreto, un operador de inicialización guiada, que genera individuos con pocas variables y, por tanto, muy generales; un operador de cruce multi-punto; un operador de mutación orientada con capacidad para eliminar o modificar aleatoriamente un gen de un individuo; y el operador de reemplazo de la población basado en la ordenación rápida por frentes de dominancia propia del algoritmo NSGA-II. Asimismo, se utiliza una población élite y un mecanismo de competición adicional basado en el proceso de competición de tokens [13]. En la actualización de esta población élite es cuando los individuos cooperan entre sí con el objetivo de obtener una población élite con la atipicidad [3] media más elevada. Esta población élite se actualiza en el operador de reinicialización, que se activa si la población actual no ha sido capaz de cubrir ejemplos no cubiertos anteriormente por un 5 % del total de las evaluaciones totales con el objetivo de evitar estancamientos en óptimos locales.

Finalmente, una vez termina el proceso evolutivo, se realiza un filtro de post-procesamiento con el fin de eliminar aquellas reglas que no tengan una calidad suficiente para el experto. En concreto, para el algoritmo MOEA-EFEP se proponen tres filtros diferentes: obtener patrones con un valor de confianza superior al 60 %, obtener sólo patrones minimales u obtener sólo patrones maximales.

La validez del método propuesto se estudia a través de un exhaustivo estudio experimental con 50 conjuntos de datos con tres objetivos diferentes: por un lado, se plantea la elección de la mejor representación del conocimiento; por otro, se plantea la elección del mejor filtrado de post-procesamiento y, finalmente, se compara MOEA-EFEP con aquellos métodos más relevantes para EPM en función de su metodología de extracción de patrones tal y como se expone en [8]. Todos los resultados obtenidos han sido avalados mediante el uso de test estadísticos no-paramétricos.

En el estudio experimental realizado se demuestra que la capacidad de las reglas en forma normal disyuntiva para la extracción de patrones emergentes con un mayor equilibrio

entre generalidad y fiabilidad de los resultados. Por otro lado, se demostró la calidad de las reglas extraídas mediante el uso del filtro de post-procesamiento basado en valores de confianza mayores al 60 %. Por último, MOEA-EFEP superó de manera significativa al resto de métodos comparados en cuanto a la generalidad de las reglas descriptivas con una fiabilidad similar utilizando para ello un número de reglas mucho menor. Por lo tanto, MOEA-EFEP es un algoritmo que obtiene un modelo de patrones emergentes con el mejor balance generalidad-fiabilidad así como el modelo de reglas más simple.

#### AGRADECIMIENTOS

Este trabajo ha sido subvencionado por el Ministerio de Economía y Competitividad bajo el proyecto TIN2015-68454-R y el contrato predoctoral FPI referencia BES-2016-077738 asociado al mismo (Fondos FEDER).

#### REFERENCIAS

- [1] A. M. García-Vico, C. J. Carmona, P. González, and M. J. del Jesus, “Moea-efep: Multi-objective evolutionary algorithm for extracting fuzzy emerging patterns,” *IEEE Transactions on Fuzzy Systems*, In Press.
- [2] P. Kralj-Novak, N. Lavrac, and G. I. Webb, “Supervised Descriptive Rule Discovery: A Unifying Survey of Constraint Set, Emerging Pattern and Subgroup Mining,” *Journal of Machine Learning Research*, vol. 10, pp. 377–403, 2009.
- [3] C. J. Carmona, M. J. del Jesus, and F. Herrera, “A Unifying Analysis for the Supervised Descriptive Rule Discovery via the Weighted Relative Accuracy,” *Knowledge-Based Systems*, vol. 139, pp. 89–100, 2018.
- [4] W. Kloesgen, “Explora: A Multipattern and Multistrategy Discovery Assistant,” in *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence, 1996, pp. 249–271.
- [5] S. Wrobel, “An Algorithm for Multi-relational Discovery of Subgroups,” in *Proc. of the 1st European Symposium on Principles of Data Mining and Knowledge Discovery*, ser. LNAI, vol. 1263. Springer, 1997, pp. 78–87.
- [6] S. D. Bay and M. J. Pazzani, “Detecting group differences: Mining contrast sets,” *Data Mining and Knowledge Discovery*, vol. 5, no. 3, pp. 213–246, 2001.
- [7] G. Z. Dong and J. Y. Li, “Efficient Mining of Emerging Patterns: Discovering Trends and Differences,” in *Proc. of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM Press, 1999, pp. 43–52.
- [8] A. M. García-Vico, C. J. Carmona, D. Martín, M. García-Borroto, and M. J. del Jesus, “An overview of emerging pattern mining in supervised descriptive rule discovery: Taxonomy, empirical study, trends and prospects,” *WIREs: Data Mining and Knowledge Discovery*, vol. 8, no. 1, 2018.
- [9] L. Wang, H. Zhao, G. Dong, and J. Li, “On the complexity of finding emerging patterns,” in *Proc. of the 28th Annual International Computer Software and Applications Conference*, vol. 2, 2004, pp. 126–129.
- [10] G. Z. Dong, J. Y. Li, and X. Zhang, “Discovering jumping emerging patterns and experiments on real datasets,” in *Proc. on International Database Conference Heterogeneous and Internet Databases*, 1999, pp. 155–168.
- [11] K. Ramamohanarao and H. Fan, “Patterns Based Classifiers,” *World Wide Web*, vol. 10, no. 1, pp. 71–83, 2007.
- [12] K. Deb, A. Pratap, S. Agrawal, and T. Meyarivan, “A fast and elitist multiobjective genetic algorithm: NSGA-II,” *IEEE Transactions Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.
- [13] K. S. Leung, Y. Leung, L. So, and K. F. Yam, “Rule Learning in Expert Systems Using Genetic Algorithm: 1, Concepts,” in *Proc. of the 2nd International Conference on Fuzzy Logic and Neural Networks*, K. Jizuka, Ed., 1992, pp. 201–204.

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

**MAEB 8.2: SESIÓN ESPECIAL:  
ALGORITMOS PARALELOS**

**Organizadores:**

ENRIQUE ALBA Y GABRIEL LUQUE







# Explotación de Paralelismo Multinivel e Híbrido en Metaheurísticas Híbridas

José M. Cecilia, Baldomero Imbernón

*Bioinformatics and High Performance Computing Research Group (BIO-HPC)*

*Polytechnic School, University Católica San Antonio of Murcia (UCAM)*

Murcia, Spain

{jmcecilia,bimbernon}@ucam.edu

Javier Cuenca

*Department of Engineering and Technology of Computers*

*University of Murcia*

Murcia, Spain

jcuenca@um.es

José-Matías Cutillas-Lozano, Domingo Giménez

*Department of Computing and Systems*

*University of Murcia*

Murcia, Spain

{josematias.cutillas,domingo}@um.es

**Resumen**—Los sistemas computacionales actuales están formados por nodos que comprenden CPUs *multicore* junto con uno o varios coprocesadores (normalmente GPUs pero ocasionalmente también MICs), de forma que se dispone de un sistema híbrido y heterogéneo. Por otro lado, el desarrollo de metaheurísticas híbridas y de hiperheurísticas que trabajan sobre ellas también sigue una estructura híbrida, en la que se puede explotar paralelismo multinivel para llevar a cabo computaciones con distinto volumen de cómputo (heterogéneas). En este trabajo analizamos la combinación de paralelismo híbrido y heterogéneo a los dos niveles, de software y de hardware, en la aplicación de metaheurísticas híbridas. Se realizan experimentos con la aplicación de metaheurísticas a dos problemas, uno de *docking* de moléculas y otro de modelos de autoregresión vectorial, sobre nodos *multicore+multiGPU*.

**Index Terms**—metaheurísticas, hiperheurísticas, paralelismo híbrido, paralelismo heterogéneo, *docking* de moléculas, modelos de autoregresión vectorial

## I. INTRODUCCIÓN

Las metaheurísticas se utilizan para la aproximación de soluciones de problemas de gran dificultad computacional [1]–[3]. Hay variedad de métodos metaheurísticos, básicamente agrupados en dos clases: distribuidos o basados en poblaciones [4], [5], y de búsqueda local, y también métodos híbridos [6], [7] que combinan las características de diferentes metaheurísticas para una mejor adaptación al problema con el que se trabaja. Así, el *software* es híbrido al combinar distintas técnicas, y heterogéneo en el sentido de que cada uno de sus componentes tiene un coste computacional distinto.

Con la aparición de la computación paralela se han desarrollado versiones paralelas de las metaheurísticas, o nuevas metaheurísticas paralelas [8]. Los nodos de la mayoría de los sistemas computacionales actuales están formados por sistemas multinúcleo junto con coprocesadores, que son principalmente GPUs (Graphics Processing Unit) y MICs (Many

Integrated Core), por lo que se está trabajando en la adaptación y optimización de software para este tipo de sistemas híbridos, y, en particular, hay trabajos sobre metaheurísticas para GPU [9], [10]. Además, el *hardware* sobre el que se trabaja es híbrido y heterogéneo, con elementos computacionales con arquitecturas distintas, en distinto número y distinta velocidad, y está organizado en muchos casos de forma jerárquica (un *cluster* con nodos híbridos *multicore+GPU*, GPUs organizadas en *grids* y bloques...).

Esta situación propicia la línea de trabajo que se presenta: análisis de la combinación de las características híbridas, heterogéneas y jerárquicas de *software* y *hardware* para explotar el paralelismo y obtener beneficios en cuanto a reducir el tiempo de ejecución o mejorar las soluciones obtenidas.

Trabajamos con metaheurísticas híbridas desarrolladas a partir de un esquema parametrizado [11], que combina características de metaheurísticas distribuidas y de búsqueda local, y se ha aplicado a diversidad de problemas: *p*-hub, asignación de tareas a procesos, y modelado de ecuaciones simultáneas [11]; consumo de electricidad en explotación de pozos de agua [12]; determinación de constantes en ecuaciones cinéticas [13], etc. Además, al estar el esquema parametrizado, se puede utilizar para diseñar hiperheurísticas que buscan en el espacio de los parámetros que determinan las metaheurísticas [14].

El esquema parametrizado se puede ampliar a esquemas paralelos que incluyen parámetros de paralelismo dependiendo del sistema computacional destino (memoria compartida [15] o paso de mensajes [16]), con una paralelización unificada para las distintas metaheurísticas híbridas del esquema.

Analizamos la adaptación del esquema metaheurístico parametrizado a sistemas más complejos: nodos *multicore+multiGPU*, posiblemente con GPUs de distintas características. Y los problemas a los que se aplican las metaheurísticas tienen una característica que facilita el uso eficiente de la alta capacidad computacional de los coprocesadores: alto coste de cálculo del *fitness*, que puede delegarse a

las GPUs.

Se utilizan dos problemas: *docking* de moléculas y modelo de autoregresión vectorial; y un tercer problema es la búsqueda por medio de hiperheurísticas (programadas como metaheurísticas) de metaheurísticas apropiadas para estos dos problemas básicos. El mayor coste computacional reside en el cálculo del *fitness*, y en las hiperheurísticas el cálculo del *fitness* se hace a su vez con la aplicación de metaheurísticas al problema básico.

El resto del trabajo está estructurado de la siguiente manera. La Sección II muestra el esquema metaheurístico parametrizado que se utiliza, y se comentan las características de las hiperheurísticas sobre este esquema. Las posibilidades de paralelización del esquema para multicore+multiGPU se comentan en la Sección III. Los dos problemas básicos usados como casos de prueba se describen en la Sección IV, y la Sección V muestra algunos resultados experimentales en la aplicación a los dos problemas básicos y a hiperheurísticas para el problema del *docking*. Las conclusiones y posibles trabajos futuros se resumen en la Sección VI.

## II. ESQUEMA PARAMETRIZADO DE METAHEURÍSTICAS E HIPERHEURÍSTICAS

Resumimos las ideas generales de los esquemas metaheurísticos parametrizados usados en este trabajo. Se pueden encontrar más detalles del esquema, de su aplicación a varios problemas de optimización y un estudio estadístico de la influencia de los parámetros en [11]. El esquema se muestra en el Algoritmo 1. Incluye Parámetros Metaheurísticos en cada una de las funciones básicas. No es un esquema general que incluya todas las posibles metaheurísticas (incontables) sino que depende de la implementación de las funciones básicas y de los parámetros que se incluyan en ellas. Instancias concretas de los parámetros pueden dar lugar a metaheurísticas básicas o a hibridaciones suyas. Por ejemplo, en [11] se implementan versiones de Algoritmos Genéticos, Búsqueda Dispersa y GRASP (Greedy Randomized Adaptive Search Procedure), y otras de las referencias mencionadas incluyen también Búsqueda Tabú. La mayoría de los parámetros son generales para el esquema, pero puede haber algunos propios del problema al que se aplican las metaheurísticas. Una descripción detallada se encuentra en las referencias previas.

Las hiperheurísticas que consideramos son a la vez metaheurísticas con el mismo esquema parametrizado, pero el significado de los parámetros es distinto, ya que depende del problema al que se aplican, que en este caso es el de búsqueda de metaheurísticas híbridas satisfactorias para el problema básico considerado. El esquema metaheurístico para implementar hiperheurísticas se muestra en el Algoritmo 2. Es igual al del Algoritmo 1 con la única diferencia los elementos con los que se trabaja (ahora son vectores de parámetros metaheurísticos) y el *fitness* asociado a cada elemento (metaheurística), que se obtiene con la aplicación de la metaheurística representada por el vector de parámetros metaheurísticos a uno o varios problemas de entrenamiento. Algunas formas de calcular el *fitness* se discuten en [14].

## III. ESQUEMAS PARALELOS PARA MULTICORE+MULTIGPU

Hemos desarrollado esquemas paralelos para memoria compartida [15] y paso de mensajes [16], y hemos analizado la utilización de esquemas parametrizados en la resolución de problemas particulares en nodos con coprocesadores. Por ejemplo, en [17] se analiza la aplicación de hiperheurísticas al problema de *docking* en un MIC. El esquema paralelo es el de memoria compartida, pero los MIC pueden ser considerados *manycore* más que multicore al ser el número de procesos mucho más elevado, y esto hace que la explotación del paralelismo a varios niveles (en la hiperheurística y las metaheurísticas donde ella busca) sea más adecuado para estos sistemas.

En el caso de la explotación de paralelismo de GPUs el esquema paralelo es distinto de los dos anteriores, pues la programación en GPUs sigue un modelo SIMD. El desarrollo de metaheurísticas para GPUs es un campo de investigación actual [9], [10], y hemos utilizado el esquema parametrizado para el problema del *docking* en nodos con GPUs, ya sean locales o virtualizadas [18], lo que acelera la computación y facilita encontrar soluciones mejores en menor tiempo.

En este trabajo analizamos por primera vez el diseño de metaheurísticas parametrizadas de forma general para explotar toda la capacidad computacional que proporcionan los nodos multicore+multiGPU. Para analizar el problema de forma general consideramos dos problemas, que además tienen alto coste computacional, lo que es necesario para que la explotación eficiente de los coprocesadores muestre todo su potencial.

Las metaheurísticas y las hiperheurísticas que trabajan sobre ellas siguen el mismo esquema parametrizado (algoritmos 1 y 2), con diferencias en la implementación de las funciones y los parámetros, dependiendo del problema subyacente a que se aplican. Así, la versión de memoria compartida es común a metaheurísticas e hiperheurísticas (Algoritmo 3), y consiste en la paralelización independiente de las funciones básicas del esquema, con inclusión de parámetros de paralelismo que determinan el número de hilos a usar en cada función. Hay funciones donde se tratan varios elementos dentro de un bucle, y se paraleliza el bucle estableciendo un determinado número de hilos. En las funciones de mejora se tratan varios elementos, en un bucle que se paraleliza con un cierto número de hilos, y para cada elemento se analiza su vecindad, lo que se hace con otro bucle con un número de hilos diferente en un segundo nivel de paralelismo. Como las hiperheurísticas llaman a metaheurísticas para el cálculo del *fitness*, llegamos a tener en algunos casos hasta cuatro niveles de paralelismo, y se podría determinar en número de hilos en cada nivel para la mayor reducción del tiempo de ejecución teniendo en cuenta las características del sistema computacional [17].

En sistemas con paralelismo híbrido multicore+multiGPU el código correrá en la CPU, que delegará a GPU partes con alto coste computacional. El paralelismo de GPU puede explotarse a distintos niveles de entre los que aparecen en el esquema de memoria compartida. Los datos con los que trabajar en GPU se

**Algorithm 1** Esquema metaheurístico parametrizado

---

```

Initialize(S, ParamIni) //Generación del conjunto inicial, posiblemente con mejora de elementos
while (not EndCondition(S, ParamEnd)) do
  SS=Select(S, ParamSel) //Selección de elementos para combinación
  SS1=Combine(SS, ParamCom) //Combinación de pares de elementos
  SS2=Improve(S, SS1, ParamImp) //Mejora de algunos elementos, posiblemente con diversificación
  S=Include(S, SS1, SS2, ParamInc) //Actualización del conjunto de referencia
end while

```

---

**Algorithm 2** Esquema metaheurístico parametrizado para la implementación de hiperheurísticas

---

```

Initialize(S, ParamIni) //Generación de un conjunto inicial de metaheurísticas
while (not EndCondition(S, ParamEnd)) do
  SS=Select(S, ParamSel) //Selección de metaheurísticas para combinación
  SS1=Combine(SS, ParamCom) //Combinación de pares de metaheurísticas para obtener nuevas metaheurísticas
  SS2=Improve(S, SS1, ParamImp) //Mejora y diversificación de metaheurísticas para obtener otras más apropiadas
  para el problema con que se trabaja
  S=Include(S, SS1, SS2, ParamInc) //Actualización del conjunto de metaheurísticas
end while

```

---

**Algorithm 3** Versión de Memoria Compartida del esquema metaheurístico parametrizado

---

```

Initialize(S, ParamIni, HilosIni) //Número de hilos en la generación, y número de hilos sobre los elementos a
mejorar y un segundo nivel para hilos que analizan la vecindad
while (not EndCondition(S, ParamEnd)) do
  SS=Select(S, ParamSel, HilosSel) //Número de hilos en bucle de selección
  SS1=Combine(SS, ParamCom, HilosCom) //Número de hilos en bucle de combinación
  SS2=Improve(S, SS1, ParamImp, HilosImp) //Número de hilos sobre los elementos a mejorar o diversificar, y un
segundo nivel para hilos que analizan la vecindad
  S=Include(S, SS1, SS2, ParamInc, HilosInc) //Número de hilos en bucles para tratar los elementos a incluir
end while

```

---

transfieren de CPU a GPU, y los resultados a la inversa, y las transferencias CPU-GPU pueden ser costosas, por lo que habrá que realizar implementaciones donde se solapen computación y transferencias, y además el volumen de trabajo a realizar en GPU en cada llamada debe ser grande. Algunos niveles a los que pueden trabajar las GPUs en el esquema del Algoritmo 3 son:

- El mayor nivel corresponde al esquema de islas, con una isla por GPU en un sistema multicore+multiGPU, dividiendo los conjuntos en subconjuntos y asignando cada subconjunto a una GPU. El trabajo que se delega a las GPU es de propósito general y no sigue el modelo SIMD, que es el más adecuado para obtener buenas prestaciones en GPU.
- Si bajamos a nivel de paralelización dentro de cada función básica, el esquema se ejecuta en CPU y las funciones trabajan sobre elementos por medio de bucles, con cada iteración del bucle realizada por un hilo. Cada hilo puede tener asociada una GPU a la que delega el tratamiento del elemento, que se transfiere a la GPU, que devuelve a CPU el resultado. Las funciones básicas tienen costes distintos, por lo que habrá que determinar para cada una, dependiendo de cómo esté implementada, si es conveniente delegar el trabajo a GPU o realizarlo en CPU.

Además, algunas funciones conllevan comparaciones y bifurcaciones en el análisis de la vecindad, por lo que, de nuevo, no tenemos un modelo SIMD.

- En un siguiente nivel las GPUs se utilizarían para el cálculo del *fitness*. Como en algunas funciones hay que calcular el *fitness* de los objetos obtenidos (en la generación inicial, al combinar, al analizar vecindades en las funciones de mejora), se pueden agrupar los cálculos de los *fitness* de todos los elementos, que se realizarían de nuevo en un bucle, con cada hilo delegando el cálculo de un elemento a la GPU que tiene asociada. De esta forma el trabajo que realizan las GPUs puede seguir el modelo SIMD si el cálculo del *fitness* se realiza a través de funciones matriciales, como es el caso de los problemas con los que experimentamos en este trabajo.
- En un último nivel serían todas las GPUs las que colaboraran en el cálculo del *fitness* de cada individuo. Podría ser una buena opción cuando este cálculo tenga un alto coste computacional, lo que puede ocurrir con las hiperheurísticas, donde el cálculo conlleva la aplicación completa de una metaheurística a una instancia del problema básico.

La mejor opción puede ser una combinación de las dos versiones intermedias, determinando el nivel al que trabajan las

GPU dependiendo del coste de la rutina básica y del número de elementos que se trate en cada nivel. El Algoritmo 4 muestra los puntos en los que se pueden usar las GPUs. Para cada rutina se indica con CPU o GPU el componente donde se ejecuta. Las rutinas sobre CPU usan paralelismo OpenMP. En las rutinas de mejora hay que determinar en cuál de los dos niveles de paralelismo es preferible utilizar las GPUs.

**Algorithm 4** Asignación de trabajo a CPU y GPU en un esquema parametrizado de metaheurísticas para multicore+multiGPU

```

InitializeCPU(Sini,ParamIni)
ComputeFitnessGPU(Sini,ParamIni)
ImproveGPU(Sini,Sref,ParamImpIni) //2 posibles niveles
while not EndConditionCPU(Sref,ParamEndCon) do
  SelectCPU(Sref,Ssel,ParamSel)
  CombineCPU(Ssel,Scom,ParamCom)
  ComputeFitnessGPU(Scom,ParamCom)
  DiversifyCPU(Sref,Scom,Sdiv,ParamDiv)
  ComputeFitnessGPU(Sdiv,ParamDiv)
  ImproveGPU(Scom,Sdiv,ParamImp) //2 posibles niveles
  IncludeCPU(Scom,Sdiv,Sref,ParamInc)
end while

```

#### IV. PROBLEMAS BÁSICOS

Se comentan las características generales de los dos problemas de optimización que se han utilizado en los experimentos.

##### IV-A. Docking de Moléculas

Se dispone de una molécula de gran dimensión (receptor) y otra menor (ligando), y se quiere encontrar la mejor forma en que el ligando se acopla con el receptor, de acuerdo con una función de *scoring*. En la bibliografía se encuentran varias funciones que se pueden usar [19], y en ellas se mide el acoplamiento considerando cada átomo en el receptor y el ligando, con lo que son funciones de alto coste y con un esquema de cómputo regular, que es apropiado para ser utilizado en GPU. Cada posición del ligando viene determinada por tres coordenadas para indicar la posición en el espacio de un átomo de referencia, y otras tres para indicar los giros con respecto a esta referencia; además, el ligando puede tener puntos donde se puede flexionar. Así, cada elemento viene determinado por las variables que indican la posición del ligando. Además, hay varias regiones independientes (*spots*) en la superficie del receptor donde el ligando puede acoplarse, por lo que la búsqueda en los *spots* se realiza de forma independiente, lo que significa que las metaheurísticas realizan la búsqueda con poblaciones independientes para cada *spot*. Teniendo en cuenta que el número de *spots* puede ser de unos cientos, y el número de átomos de receptor y ligando de unos miles y unos cientos, el coste computacional de la aplicación de metaheurísticas a este problema es alto, y es conveniente la utilización de sistemas de altas prestaciones del tipo multicore+multiGPU, posiblemente con GPUs virtualizadas para disponer de mayor potencia computacional [18].

##### IV-B. Modelos de Autoregresión Vectoriales

Consideramos  $d$  parámetros de los que se han tomado valores en  $t$  instantes de tiempo. Los valores para el instante  $k$ ,  $1 \leq k \leq t$ , se almacenan en un vector  $y^{(k)} = (y_1^{(k)}, \dots, y_d^{(k)}) \in R^{1 \times d}$ . Y los  $t$  vectores de datos se pueden organizar en una matriz  $Y \in R^{t \times d}$ :

$$\begin{pmatrix} y_1^{(1)} & \dots & y_d^{(1)} \\ \vdots & \ddots & \vdots \\ y_1^{(t)} & \dots & y_d^{(t)} \end{pmatrix} \quad (1)$$

Consideramos también dependencias temporales con  $i$  instantes de tiempo anteriores. Puede haber variables externas al modelo, vector  $z$ , con  $e$  variables. La dependencia de vectores de datos de un instante  $j$  en función de los vectores de datos de instantes anteriores (hasta  $i$  para las variables internas y  $k$  para las externas) se puede representar como

$$y^{(j)} \approx y^{(j-1)} A_1 + y^{(j-2)} A_2 + \dots + y^{(j-i)} A_i + z^{(j-1)} B_1 + z^{(j-2)} B_2 + \dots + z^{(j-k)} B_k + a \quad (2)$$

donde  $A_l$ ,  $1 \leq l \leq i$ , son matrices de dimensión  $d \times d$  que representan la dependencia de los datos con los valores de  $l$  instantes anteriores,  $B_l$ ,  $1 \leq l \leq k$ , son matrices de tamaño  $e \times d$ , y  $a$  es un vector de términos independientes.

Cada elemento del espacio de búsqueda de una metaheurística viene dado por los valores de las matrices  $A$ ,  $B$  y  $a$ , y el *fitness* se obtiene con multiplicaciones matriciales y la norma de la diferencia entre los valores de la serie temporal (ecuación 1) y los que se obtienen en cada instante de tiempo utilizando los instantes anteriores y dichas matrices (ecuación 2) [20]. Así, también ahora las operaciones son apropiadas para el modelo SIMD, pero las dimensiones ( $d$ ,  $e$ ,  $i$ ,  $k$ ) son bastante menores que en el problema anterior.

#### V. RESULTADOS EXPERIMENTALES

Se resumen los resultados de los experimentos realizados en nodos computacionales con CPUs y GPUs de distintos tipos y uno de ellos con varias GPUS:

- **marite**: contiene un hexa-core CPU AMD Phenom II X6 1075T a 3.00 GHz, con arquitectura x86-64, 16 GB de RAM, cachés privadas L1 y L2 de 64 KB y 512 KB, y una caché L3 de 6 MB compartida por todos los núcleos. Incluye una GPU NVidia GeForce GTX 480 (Fermi) con 1536 MB de memoria global y 480 núcleos CUDA (15 Streaming Multiprocessors y 32 Streaming Processors por SM).
- **saturno**: tiene 4 CPU Intel Xeon E7530 (hexa-core) a 1.87 GHz, con arquitectura x86-64, 32 GB de RAM, cachés privadas L1 y L2 de 32 KB y 256 KB por núcleo, y una caché L3 de 12 MB compartida por los núcleos de cada socket. Incluye una GPU NVidia Tesla K20c (Kepler) con 4800 MB de memoria global y 2496 núcleos CUDA (13 Streaming Multiprocessors y 192 Streaming Processors por SM).



- **jupiter**: con 2 CPU Intel Xeon E5-2620 (hexa-core) a 2.00 GHz, con arquitectura x86-64, 32 GB de memoria RAM, cachés privadas L1 y L2 de 32 KB y 256 KB por núcleo, y una caché L3 de 15 MB compartida por los núcleos en cada socket. Incluye 6 GPUs: 2 NVidia Tesla C2075 (Fermi) con 5375 MB de memoria global y 448 núcleos CUDA (14 Streaming Multiprocessors y 32 Streaming Processors per SM), y 4 GPUs en dos placas, cada una es una con 2 NVidia GeForce GTX 590 (Fermi) con 1536 MB de memoria global y 512 núcleos CUDA (16 Streaming Multiprocessors y 32 Streaming Processors per SM).
- **venus**: con 2 CPU Intel Xeon E5-2620 (hexa-core) a 2.40 GHz, arquitectura x86-64, 64 GB de memoria RAM, cachés privadas L1 y L2 de 32 KB y 256 KB por núcleo, y una caché L3 de 15 MB compartida por todos los núcleos de un socket. Incluye una GPU NVidia GeForce GT 640 (Kepler) con 1024 MB de Global Memory y 384 núcleos CUDA (2 Streaming Multiprocessors y 192 Streaming Processors por SM).

La Tabla I compara los tiempos obtenidos en **jupiter** con paralelismo GPU (sólo se usa una Tesla C2075) y con CPU con un núcleo, para seis metaheurísticas híbridas aplicadas al problema de *docking* de moléculas con el par receptor-ligando COMT (se pueden consultar los detalles en [21]). Se alcanza un speed-up de GPU con respecto a CPU de alrededor de 43. La ventaja de usar GPUs es clara, incluso en este caso en que la GPU se usa sólo en el cálculo de la función de *scoring*.

Tabla I

TIEMPO DE EJECUCIÓN (EN SEGUNDOS) DE VERSIONES CPU Y GPU, Y SPEED-UP DE GPU RESPECTO A CPU, PARA DIFERENTES METAHEURÍSTICAS APLICADAS AL PAR RECEPTOR-LIGANDO COMT, EN JUPITER

Metaheuristic	CPU	GPU	CPU/GPU
M1	140.48	10.42	39.35
M2	193.67	13.81	43.55
M3	1,911.52	9.62	54.16
M4	209.56	9.59	34.43
M5	262.65	8.55	35.51
M6	1,379.93	10.39	53.89

El par con el que se ha experimentado para los resultados de la Tabla I es pequeño pero los tiempos de ejecución pueden ser grandes dependiendo de la metaheurística. En el caso de las hiperheurísticas, el tiempo crece enormemente dado que se busca en un espacio de metaheurísticas. En una hiperheurística se puede tener hasta cuatro niveles de paralelismo (dos en la hiperheurística y hasta dos en la metaheurística), por lo que es necesario experimentar con las distintas combinaciones del número de hilos en los cuatro niveles para obtener la mejor combinación. Para simplificar la experimentación dado que el tiempo de cada experimento es bastante largo, hemos considerado los tres niveles de paralelismo de mayor nivel, con lo que las metaheurísticas usan sólo paralelismo de un nivel. La Figura 1 compara el tiempo de ejecución (segundos) con la versión de memoria compartida para una hiperheurística particular, con diferentes combinaciones de número de hilos

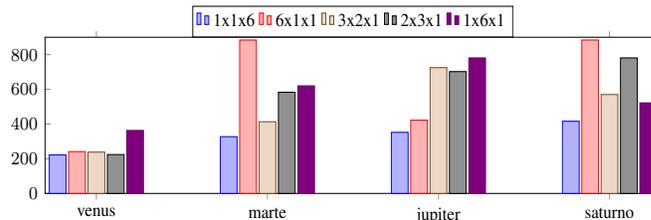


Figura 1. Tiempo de ejecución (segundos) con la versión de memoria compartida para una hiperheurística, con diferentes combinaciones de número de hilos en tres niveles de paralelismo, con un total de seis hilos y en los cuatro nodos considerados.

Tabla II

COMPARACIÓN DEL TIEMPO DE EJECUCIÓN (EN SEGUNDOS) DE TRES HIPERHEURÍSTICAS CON PARALELISMO DE MEMORIA COMPARTIDA EN CPU Y CON PARALELISMO GPU, EN LOS CUATRO NODOS CONSIDERADOS.

	H1	H2	H3
marte			
multicore	13035	4541	23957
multicore+GPU	903	335	1348
CPU/GPU	14.44	13.56	17.77
venus			
multicore	4021	1423	6346
multicore+GPU	3197	1857	5065
CPU/GPU	1.26	0.77	9.67
jupiter			
multicore	8045	3509	14115
multicore+GPU	990	514	1459
CPU/GPU	8.13	6.83	9.67
saturno			
multicore	6150	1595	8582
multicore+GPU	563	200	823
CPU/GPU	10.92	7.98	10.43

en tres niveles de paralelismo, con un total de seis hilos y en los cuatro nodos considerados. Se obtienen resultados similares con otras hiperheurísticas. La mejor combinación de hilos es  $1 \times 1 \times 6$  en todos los nodos, con algunas diferencias en la comparación de las distintas combinaciones dependiendo del nodo, lo que es normal dada la distinta capacidad computacional de los nodos y que hay aleatoriedad en las ejecuciones. Para evitar la aleatoriedad se deberían realizar varias ejecuciones por cada combinación, pero, dado el alto coste computacional, esto conllevaría unos tiempos de experimentación excesivos.

La Tabla II compara el tiempo de ejecución de tres hiperheurísticas cuando se explota paralelismo de memoria compartida con un número de hilos igual al número de cores en el nodo y cuando se usa GPU para el cálculo de las funciones de *scoring*. Se ha usado de nuevo el par COMT. Se comprueba que el tiempo de ejecución es mucho mayor que el de una única metaheurística, y el tiempo de ejecución con la explotación del paralelismo híbrido multicore+GPU es en general mucho menor que con paralelismo de memoria compartida. Sólo en el caso de **venus**, que tiene la CPU más rápida y la GPU más lenta, son los tiempos comparables.

El uso de GPU también puede dar resultados satisfactorios para el problema de modelos de autoregresión vectorial, pero

en este caso el coste computacional es mucho menor que en el *docking* de moléculas, por lo que el uso de GPU resulta ventajoso sólo para problemas muy grandes que seguramente no se corresponden con casos de aplicaciones reales. Por ejemplo, en **.jupiter**, cuando se utiliza una única GPU en el nivel más bajo (cálculo del *fitness*, que en este caso es una multiplicación de matrices y el cálculo de la norma), con valores de los parámetros  $t = 200$ ,  $d = 4$ ,  $e = 2$ ,  $i = 3$  y  $k = 2$  el speed-up de GPU respecto a CPU es 0.83, con lo que es preferible no usar GPU. Pero para problemas mayores el speed-up aumenta: para  $d = 5$ ,  $e = 3$ ,  $i = 3$  y  $k = 2$  es 0.92, y para  $d = 5$ ,  $e = 3$ ,  $t_y = 4$  y  $t_z = 2$  llega a 1.25.

El uso de más GPUs reduce el tiempo de ejecución sólo para tamaños muy grandes, por lo que para este problema es necesario optimizar más la utilización de GPUs. Un ejemplo es la asignación dinámica de trabajo. En una ejecución en **.jupiter** con cuatro GPUs (dos de cada tipo) y tamaños mayores que en el experimento anterior ( $t = 500$ ), el tiempo de ejecución fue 1854 segundos cuando se asignó el cálculo del *fitness* a las GPUs con el mismo número de elementos para cada GPU. Al asignar de forma estática el doble de elementos a las GPUs más rápidas (en teoría son el doble de rápidas) el tiempo subió a 2249 segundos. Y el menor tiempo se obtuvo con asignación dinámica, con 1598 segundos.

## VI. CONCLUSIONES Y TRABAJOS FUTUROS

En este trabajo se discute la utilización de paralelismo híbrido multicore+multiGPU en la aplicación de metaheurísticas híbridas basadas en un esquema parametrizado de metaheurísticas. En el esquema hay paralelismo en distintos niveles, y se analiza en qué niveles sería conveniente la utilización de GPUs. Además, sobre el esquema se pueden desarrollar hiperheurísticas que se implementan como metaheurísticas con ese esquema y que buscan en el espacio de metaheurísticas para un problema básico implementadas con el mismo esquema. Como el esquema paralelo parametrizado tiene dos niveles de paralelismo, la implementación de hiperheurísticas da lugar a un máximo de cuatro niveles, y se debe analizar la mejor combinación de hilos en cada nivel y en qué partes del esquema paralelo utilizar GPU.

Se han considerado dos problemas básicos para analizar el esquema: *docking* de moléculas y modelos de autoregresión vectorial. Los dos problemas tienen alto coste computacional y el cálculo del *fitness* se hace con computación matricial que sigue un esquema SIMD, por lo que se puede explotar paralelismo GPU. Para el primer problema, dado el tamaño de las moléculas con las que se realiza el *docking*, el tiempo de ejecución es muy elevado, y se alcanza una gran reducción del tiempo con respecto a CPU cuando se utiliza paralelismo híbrido multicore+GPU. En el otro problema, el uso de GPU es ventajoso sólo para problemas grandes, que no se corresponden con aplicaciones en uso.

El mismo esquema puede ser utilizado en otros problemas, y estamos centrando nuestra investigación en el análisis de cómo determinar en función de los costes del problema de

optimización la forma óptima de utilizar el esquema: número de hilos y forma de uso de las GPUs en cada nivel.

## REFERENCIAS

- [1] Z. Michalewicz and D. B. Fogel, *How to Solve It: Modern Heuristics*. Springer, 2002.
- [2] J. Hromkovič, *Algorithmics for Hard Problems*. Springer, second ed., 2003.
- [3] J. Dréo, A. Pérowski, P. Siarry, and E. Taillard, *Metaheuristics for Hard Optimization*. Springer, 2005.
- [4] F. Glover and G. A. Kochenberger, *Handbook of Metaheuristics*. Kluwer, 2003.
- [5] E.-G. Talbi, *Metaheuristics - From Design to Implementation*. New York: Wiley, 2009.
- [6] G. R. Raidl, "A unified view on hybrid metaheuristics," in *Hybrid Metaheuristics, Third International Workshop, LNCS*, vol. 4030, pp. 1–12, October 2006.
- [7] C. Blum, J. Puchinger, G. R. Raidl, and A. Roli, "Hybrid metaheuristics in combinatorial optimization: A survey," *Appl. Soft Comput.*, vol. 11, no. 6, pp. 4135–4151, 2011.
- [8] E. Alba, *Parallel Metaheuristics: A New Class of Algorithms*. New York: Wiley-Interscience, 2005.
- [9] E.-G. Talbi and G. Hasle, "Metaheuristics on GPUs," *J. Parallel Distrib. Comput.*, vol. 73, no. 1, pp. 1–3, 2013.
- [10] M. Essaid, L. Idoumghar, J. Lepagnot, and M. Bréviillers, "GPU parallelization strategies for metaheuristics: a survey," *International Journal of Parallel, Emergent and Distributed Systems*, vol. 0, no. 0, pp. 1–26, 2018.
- [11] F. Almeida, D. Giménez, J.-J. López-Espín, and M. Pérez-Pérez, "Parameterised schemes of metaheuristics: basic ideas and applications with Genetic algorithms, Scatter Search and GRASP," *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, vol. 43, no. 3, pp. 570–586, 2013.
- [12] L.-G. Cutillas-Lozano, J.-M. Cutillas-Lozano, and D. Giménez, "Modeling shared-memory metaheuristic schemes for electricity consumption," in *Distributed Computing and Artificial Intelligence - 9th International Conference*, pp. 33–40, 2012.
- [13] J. Cutillas-Lozano and D. Giménez, "Determination of the kinetic constants of a chemical reaction in heterogeneous phase using parameterized metaheuristics," in *Proceedings of the International Conference on Computational Science*, pp. 787–796, 2013.
- [14] J. Cutillas-Lozano, D. Giménez, and F. Almeida, "Hyperheuristics based on parameterized metaheuristic schemes," in *Proceedings of the Genetic and Evolutionary Computation Conference*, pp. 361–368, 2015.
- [15] F. Almeida, D. Giménez, and J.-J. López-Espín, "A parameterized shared-memory scheme for parameterized metaheuristics," *The Journal of Supercomputing*, vol. 58, no. 3, pp. 292–301, 2011.
- [16] J. Cutillas-Lozano and D. Giménez, "Optimizing a parameterized message-passing metaheuristic scheme on a heterogeneous cluster," *Soft Comput.*, vol. 21, no. 19, pp. 5557–5572, 2017.
- [17] J. M. Cecilia, J. Cutillas-Lozano, D. Giménez, and B. Imbernón, "Exploiting multilevel parallelism on a many-core system for the application of hyperheuristics to a molecular docking problem," *The Journal of Supercomputing*, vol. 74, no. 5, pp. 1803–1814, 2018.
- [18] B. Imbernón, J. Prades, D. Giménez, J. M. Cecilia, and F. Silla, "Enhancing large-scale docking simulation on heterogeneous systems: An MPI vs rcuda study," *Future Generation Comp. Syst.*, vol. 79, pp. 26–37, 2018.
- [19] G. Schneider, "Virtual screening and fast automated docking methods," *Drug Discovery Today*, vol. 7, pp. 64–70, Jan. 2002.
- [20] A. L. Castaño, J. Cuenca, J.-M. Cutillas-Lozano, D. Giménez, J. J. López-Espín, and A. Pérez-Bernabeu, "Parallelism on hybrid metaheuristics for vector autoregression models," in *International Conference on High Performance Computing & Simulation*, August 2018.
- [21] B. Imbernón, J. M. Cecilia, and D. Giménez, "Enhancing metaheuristic-based virtual screening methods on massively parallel and heterogeneous systems," in *Proceedings of the 7th International Workshop on Programming Models and Applications for Multicores and Manycores*, pp. 50–58, 2016.



# Optimización evolutiva multiobjetivo distribuida mediante aplicación selectiva de operadores

Pablo García-Sánchez  
 Departamento de Ingeniería Informática  
 Universidad de Cádiz  
 Puerto Real, España  
 pablo.garciasanchez@uca.es

Julio Ortega, Jesús González, Pedro A. Castillo,  
 Juan Julián Merelo, Antonio M. Mora y Antonio Fernández-Ares  
 Departamento de Arquitectura y Tecnología de Computadores  
 Universidad de Granada  
 Granada, España  
 julio@ugr.es

**Resumen**—Este trabajo presenta un nuevo enfoque, llamado *aplicación selectiva de operadores*, para hacer frente a problemas no separables en el entorno de los algoritmos co-evolutivos multiobjetivo: en lugar de compartir secciones de individuos, cada procesador aplica los operadores de variación a un subconjunto específico de todo el individuo. Esto evita pasos adicionales para recomponer los individuos completos de otras islas antes de ser evaluados.

En este trabajo se pretende demostrar que la decisión automática del tamaño de la sección solapada, es capaz de obtener mejores resultados que la utilización del mismo tamaño independientemente del número de islas. Para ello se ha comparado con otras técnicas evolutivas colaborativas considerando diferentes números de islas y problemas. El análisis de los resultados experimentales obtenidos, utilizando diferentes métricas, muestra que nuestro enfoque puede proporcionar mejoras estadísticamente significativas con respecto al algoritmo base en problemas multiobjetivo de alta dimensionalidad.

**Index Terms**—Algoritmos multiobjetivo, NSGA-II, modelo de islas, algoritmos evolutivos distribuidos

## I. INTRODUCCIÓN

Los problemas de optimización multiobjetivo (MOP por sus siglas en inglés) son aquellos en los que varios objetivos tienen que ser optimizados a la vez [1]. Resolver un MOP implica optimizar una función compuesta por varias funciones de coste independientes, una por objetivo. En estos problemas el objetivo es obtener un conjunto de soluciones que sean mejores que el resto, considerando todos los objetivos; este conjunto se conoce como el Frente de Pareto (FP). Las soluciones en este conjunto son *no dominadas*, lo que significa que no hay otra solución que sea igual o mejor para todos los objetivos.

Este aspecto de la búsqueda de soluciones no dominadas, así como, en muchos casos, el tamaño del propio espacio de búsqueda, implica una alta demanda de tiempo computacional, lo que lleva a la propuesta de métodos paralelos y distribuidos para resolverlos [2], [3], uno de los cuales son los algoritmos evolutivos (EAs) [4].

Trabajo financiado por los proyectos SPIP2017-02116 (Dirección General de Tráfico), EphemeCH TIN2014-56494-C4-3-P, TIN2015-67020-P, DeepBio TIN2017-85727-C4-2-P y TEC2015-68752 (Ministerio de Economía y Competitividad y Fondos FEDER) y PR2018-056 (Programa de Fomento e Impulso de la Investigación y de la Transferencia de la Universidad de Cádiz 2018-2019).

Los EAs se han extendido a la optimización multiobjetivo a través de un buen número de Algoritmos Evolutivos Multiobjetivo (MOEAs, por sus siglas en inglés) [5]. Se han utilizado diferentes enfoques para paralelizar los EAs, ya que cada individuo puede ser considerado como una unidad independiente [6], [7]. Los métodos clásicos, como los EAs paralelos globales (Maestro-Esclavo), o los algoritmos espacialmente estructurados (Modelo de isla o EAs celulares) se han aplicado con éxito en el pasado [8]. Sin embargo, en el caso de los MOEAs, estos enfoques [2] necesitan ocuparse de todo el conjunto de soluciones, el FP. Esto implica el uso de diferentes mecanismos de distribución y compartición, ya que existe un equilibrio entre la mejora obtenida a partir de la paralelización y la necesidad de recombinar globalmente los resultados para identificar con precisión el FP [9].

Las MOPs del mundo real normalmente requieren un alto número de variables de decisión, lo que significa que los MOEAs necesitan tratar con individuos grandes y gastar un tiempo significativo adicional para el cruce, mutación y migración. Diferentes autores han propuesto métodos para dividir el espacio de decisión (el cromosoma) para mejorar el rendimiento y la calidad de las soluciones. En este aspecto, el modelo de co-evolución es un modelo distribuido por dimensiones en el que un problema de alta dimensionalidad se divide en otros de dimensiones más bajas [7], que evolucionan por separado. Un ejemplo de aplicación de esta técnica fue descrito en [10]. El método presentado en ese trabajo involucra a diferentes trabajadores que evolucionan subpoblaciones creadas y recombinadas por un proceso maestro, el cual realiza diferentes alternativas de recombinación de las partes devueltas por los procesos de los trabajadores.

Un enfoque similar utilizado para resolver este tipo de problemas es el de la aplicación de la Aplicación Selectiva de Operadores (ASO) presentado en este documento. En este caso, cada isla se ocupa de la totalidad del cromosoma, pero sólo modifica un fragmento en la fase de cruce y mutación en función del número de islas, utilizando todo el cromosoma para el cálculo del fitness. Esto permite hacer frente a problemas que no se pueden descomponer. En nuestro trabajo anterior [11] utilizamos este método de manera preliminar. En ese trabajo demostramos que la aplicación de los operadores de variación sólo sobre secciones específicas de todo el cromosoma mejora

la calidad de las soluciones en el mismo tiempo de cálculo para un algoritmo multi-objetivo basado en islas. Además, en lugar de hacer que cada isla se centre en un subconjunto disjuncto del cromosoma, el uso de secciones solapadas (compartidas) del cromosoma puede mejorar la calidad de las soluciones cuando se aumenta el número de islas.

Esto nos motiva a continuar esta línea de investigación utilizando un entorno más adecuado: un cluster real con hasta 128 nodos y una parametrización más completa. Además de comparar los métodos anteriores en esta nueva configuración experimental, en este trabajo proponemos un nuevo método que automáticamente establece el tamaño del solapamiento, en función del número de islas disponibles, comparándolo con versiones anteriores.

El resto del documento está organizado de la siguiente manera: después del estado del arte en MOEAs distribuidos y co-evolutivos, la metodología utilizada y los algoritmos comparados se describen en la Sección III. Después se presentan los resultados de los experimentos (Sección V), Finalmente, se discuten las conclusiones y el trabajo futuro <sup>1</sup>.

## II. ESTADO DEL ARTE

Desde principios de la década de los 2000, los EAs distribuidos y paralelos se han utilizado principalmente para aprovechar sistemas como clusters o grids [12]. Pero en el caso de los MOEAs, la distribución y paralelización es más difícil que en los EAs con un solo objetivo. Esto se debe a que en diferentes pasos del algoritmo el conjunto completo de soluciones dependientes, el FP, debe ser gestionado como un todo, dedicando tiempo a reunir a todos los individuos de los diferentes procesadores o islas.

Para resolver este problema, algunos autores han propuesto el uso de enfoques Maestro-Eslavo. Por ejemplo, [13] comparó diferentes enfoques maestro-esclavo: síncrono generacional, asíncrono generacional y asíncrono estacionario, siendo esta última la opción más prometedora.

También se ha explorado otro tipo de enfoques. El trabajo de Deb et al. [14] fue uno de los primeros enfoques para MOEAs distribuidos (dMOEAs). En ese trabajo, el dominio de las soluciones se divide en las islas mediante una transformación de coordenadas. En ese trabajo, los autores concluyeron que dividir el espacio de búsqueda es una buena idea, aunque lograr esto no es trivial. La división del espacio de búsqueda ha sido explorada por otros investigadores, por ejemplo, dividiendo la población en élites y subpoblaciones de búsqueda [15], o separándola en procesadores por objetivo [16]. Otros autores, como [17] utilizan la migración para aceptar individuos basados en la diversidad, y emigran desde áreas no superpobladas.

Abordar este tipo de problemas usando co-evolución cooperativa también ha sido estudiado en varios trabajos con enfoques más cercanos al que aquí se presenta. El enfoque de centrarse en una porción del cromosoma, como en nuestro

método de solapamiento, fue utilizado en primer lugar en el trabajo de Dorronsoro et al. [18], obteniendo un rendimiento superlineal en varios casos. Recientemente, este enfoque también ha sido probado utilizando un algoritmo de optimización de enjambre de partículas (PSO) [19], obteniendo también mejoras significativas en la velocidad y calidad de la solución.

El enfoque descrito por Dorronsoro et al. también ha sido utilizado por Kimovski et al. [10], pero implementando un método maestro-esclavo que divide la población en varios procesadores. Como en trabajos anteriores, cada nodo ejecuta un MOEA paralelo que sólo afecta a una porción de los individuos y el proceso maestro recibe todas las subpoblaciones a combinar cada cierto número de generaciones. Se utilizaron hasta 8 procesadores y se compararon varias alternativas de combinación. La principal diferencia de nuestro trabajo con respecto a los trabajos anteriores es que nuestro enfoque no difunde todas las soluciones a todas las islas para la recombinación, sino sólo una solución a una isla aleatoria, necesitando menos tiempo de comunicación. Además, los enfoques de Dorronsoro o Kimovsky limitaron el número máximo de islas a 8, mientras que en este documento hemos utilizado hasta 128 islas.

En nuestro trabajo anterior [11] utilizamos algunas de las ideas mencionadas anteriormente para comparar dos dMOEAs diferentes. El primero dividió el cromosoma en  $P$  secciones, siendo  $P$  el número de islas. Cada isla  $p$  sólo realizó la mutación y el cruce en esa parte ( $p_{th}$ ) del cromosoma (la aplicación selectiva de operadores), mientras que el *fitness* se calculó usando el individuo entero. Después de un cierto número de generaciones, los individuos fueron migrados al azar a otras islas. Las métricas de rendimiento se calcularon al final de la ejecución. El segundo método, la aplicación selectiva de operadores con islas solapadas, usaba las secciones  $p_{th-1}$  y  $p_{th+1}$  de cada cromosoma, además de la parte  $p_{th}$ . Usando la misma cantidad de tiempo, ambos métodos obtuvieron mejores resultados que un algoritmo de *baseline* que se ocupaba de todo el cromosoma en cada isla para el cruce y la mutación. Descubrimos que el rendimiento utilizando uno u otro método depende del número de secciones de los individuos y del número de islas utilizadas. Esto nos motivó a encontrar un nuevo método automático para seleccionar este número de secciones del cromosoma a utilizar, dependiendo del número de islas. Además, se realizaron experimentos previos en un modelo de isla síncrona con un único procesador y con un número limitado de islas (8, 32 y 128). En este trabajo se han utilizado 8, 16, 32, 64 y 128 islas, y en esta ocasión los experimentos se han realizado en un cluster paralelo. Por lo tanto, al mismo tiempo, estamos proponiendo un nuevo método para dividir el espacio de búsqueda individual según el número de subpoblaciones que evolucionan, y también validando el enfoque anterior.

## III. METODOLOGÍA

El objetivo de esta sección es explicar la metodología que hemos seguido para comparar las diferentes versiones de la selección de secciones a modificar en cada isla.

<sup>1</sup>Nota: una versión extendida de este artículo está siendo revisada en la revista *Applied Soft-Computing*



En este trabajo analizamos varios algoritmos basados en ASO que hemos implementado con respecto un algoritmo *baseline* multiobjetivo paralelo. Los métodos propuestos, utilizando diferentes esquemas de solapamiento, se basan en NSGA-II, como casi todos los trabajos discutidos anteriormente [13]–[18]. Por lo tanto, hemos utilizado un algoritmo NSGA-II básico distribuido sin solapar secciones como *baseline* (B).

Este algoritmo básico distribuye la población entre  $P$  islas; después de un número fijo de generaciones, un individuo en una isla dada es migrado a otra isla al azar, evitando así sincronizar el FP global cada cierto número de generaciones como lo hacen otros métodos descritos en la Sección 2. Al final de cada ejecución, los FPs de todas las islas se agregan en uno nuevo y se evalúan las medidas de calidad.

Se pueden idear diferentes alternativas de ASO para evolucionar las subpoblaciones de acuerdo con el espacio de decisión a explorar por cada isla. Al igual que en la *baseline* (B), un individuo es migrado a otra isla al azar después de un número fijo de generaciones. En la nueva isla, este individuo será considerado como uno más en la isla, cruzado y mutado de la misma manera, dependiendo del identificador de la nueva isla (de 1 a  $P$ ). Nótese que, a diferencia de otros trabajos como los descritos por Talbi et al. [12], todas las islas tratan con cromosomas completos para el cálculo del fitness, por lo que nuestro enfoque puede tratar con problemas separables y no separables.

Concretamente hemos comparado las siguientes versiones:

- **ASO con islas disjuntas (D)** En este enfoque, cada individuo del tamaño  $L$  se divide en trozos de  $P$  del tamaño  $L/P$ . Cada isla  $p$  sólo realiza crossover y mutación en la parte  $p_{th}$  de los individuos.
- **ASO con secciones solapadas (S)** Este enfoque es similar al anterior, pero cada isla también utiliza los trozos de  $p+1$  y  $p-1$  (usando el módulo) del individuo para el cruce y la migración. Por lo tanto, existe algún tipo de solapamiento de las partes cruzadas y mutadas entre las islas.
- **ASO automático con secciones solapadas (A)** Como en el método anterior, las secciones a tratar por los operadores se solapan, pero en lugar de usar una sección extra a cada lado de la sección  $p$  ( $p+1$  y  $p-1$ ), usa fragmentos  $c$  a cada lado ( $p+c$  y  $p-c$ ), siendo  $c$  un valor que depende del número de islas.

Como primera aproximación para calcular automáticamente este valor, se han utilizado los resultados mostrados en [11] como base para obtener  $c$ . En ese trabajo, el método de solapamiento (cuando  $c = 1$ ) obtuvo mejores resultados si el número de islas era mayor de 8. Por el contrario, cuando el número de islas es pequeño, no es necesario solaparlas. Por lo tanto, hemos usado este conocimiento para proponer la fórmula  $c = \text{round}(0,2 * P - 1)/2$  para calcular las secciones extra a solapar. Por lo tanto, cuando  $P = 8$  entonces  $c = 0$  (equivalente a  $D$ ), cuando  $P = 16$  entonces  $c = 1$  (equivalente a  $S$ ), y así sucesivamente. La figura 1 explica el método A, asumiendo que  $c = 2$ , por ejemplo.

#### IV. EXPERIMENTOS

En esta subsección se describen los indicadores de calidad utilizados y los experimentos. Los indicadores de calidad elegidos son:

- **Hipervolumen (HV)**: mide el área formada por todas las soluciones no dominadas encontradas con respecto a un punto de referencia. Los valores más altos implican una mejor calidad del FP.
- **Distancia Generacional Invertida (IGD)**: calcula la distancia del conjunto de soluciones obtenidas al FP óptimo. En esta métrica, cuanto más bajo, mejor.
- **Spread (S)**: Mide la dispersión entre soluciones, teniendo en cuenta la distancia euclídea entre soluciones consecutivas. Como en la métrica anterior, cuanto menor sea el valor, mejor, ya que implica soluciones distribuidas a lo largo de todo el FP.

Hemos elegido estas métricas no sólo porque se han utilizado ampliamente, especialmente en algunos de los documentos presentados en la Sección II, como [13], [15], [17], [18], sino también porque cubren diferentes criterios de calidad. La formulación matemática de estas métricas se puede encontrar en [18].

El tamaño del cromosoma ( $L$ ) es de 2048. También se ha comparado un número diferente de islas ( $P$ ): 8, 16, 32, 64 y 128. Este número máximo de islas también ha sido utilizado en un trabajo anterior en la literatura [17]. El cruce y la mutación elegidos, SBX y polinomial, también han sido utilizados previamente por otros autores en [13].

El benchmark ZDT [20] ha sido elegido debido a que es el más utilizado en esta área [13]–[15], [17]. Este benchmark incluye varias funciones, con diferentes características que son representativas de los problemas de optimización del mundo real. La formulación matemática de cada función está disponible en [20].

El criterio utilizado para terminar un experimento ha sido el tiempo de ejecución: 100 segundos por ejecución. Según Alba y Luque [21], otros criterios de parada como el número de evaluaciones necesarias para alcanzar una solución, pueden ser engañosos dependiendo del escenario estudiado. En nuestro caso hemos utilizado el tiempo en lugar del número de evaluaciones, en primer lugar porque nuestra hipótesis argumenta que el tiempo ahorrado en el cruce y la mutación se puede gastar en mejorar las subpoblaciones y se pueden lograr más operaciones y migraciones. Además, estamos utilizando un número diferente de islas (con diferentes tamaños de subpoblación) y eso podría llevar a diferentes tiempos de ejecución, por lo que sería difícil comparar diferentes tiempos y calidad de soluciones al mismo tiempo.

Hemos usado el framework ECJ [22] para ejecutar los experimentos. El código fuente usado puede descargarse de nuestro repositorio GitHub<sup>2</sup> bajo una licencia LGPL V3.

El modelo de isla se ha ejecutado de forma asíncrona, utilizando el modelo de intercambio distribuido de interpolación de ECJ, en un cluster de 16 nodos, cada uno con 16

<sup>2</sup><https://github.com/hpmoon/hpmoon-islands>

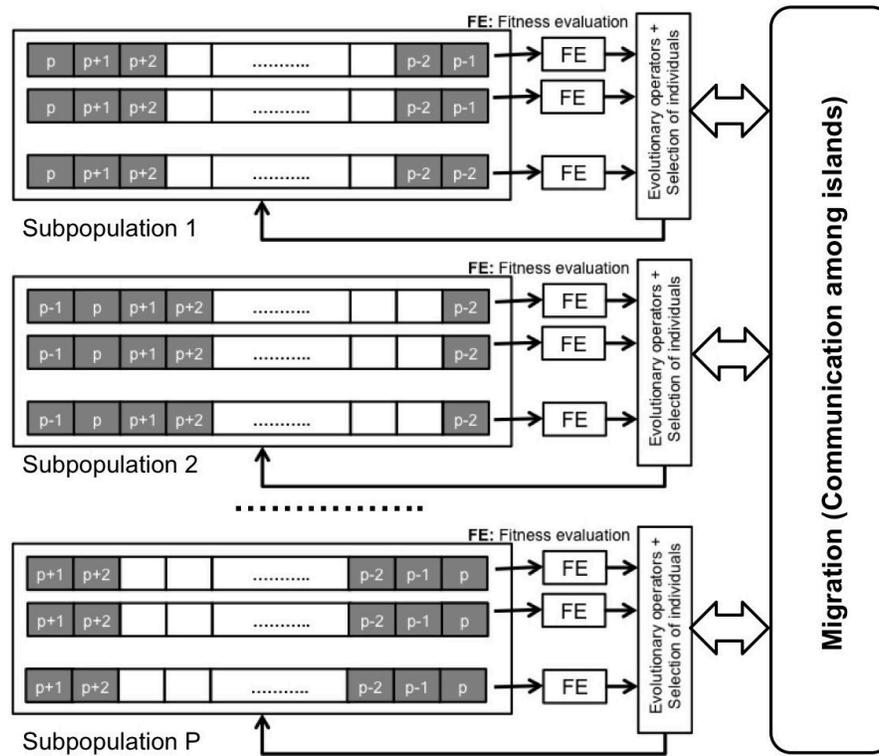


Figura 1. ASO solapado automáticamente (A): cada isla  $p$  modifica los  $p + c$ ,  $p_{th}$  y  $p - c$  componentes (en gris) de los individuos usando operadores genéticos (cruce y mutación). Además, cada isla evalúa a sus propios individuos usando el cromosoma completo. Después de un número dado de generaciones coopera con las otras islas a través de la migración. Se calcula  $c$  dependiendo del número de islas. En este caso,  $c = 2$ .

Nombre del parámetro	Valor
Tamaño global de la población ( $N$ )	1024
Selección	Torneo Binario
Tipo de reemplazo	Generacional
Tipo de crossover	SBX
Tipo de mutación	Polinomial
Probabilidad de mutación	$1/L$
Individuos por migración	1
Generaciones entre migración	5
Selección para migración	Torneo Binario
Ejecuciones por configuración	30
Número de islas ( $P$ )	8, 16, 32, 64 and 128
Tamaño del cromosoma ( $L$ )	2048
Tiempo de ejecución (s)	100

Tabla I

PARÁMETROS Y OPERADORES USADOS EN LOS EXPERIMENTOS.

procesadores Intel(R) Xeon(R) CPU E5520 @2.27GHz, 16 GB RAM, tarjetas de red Broadcom NetXtreme II BCM5716 1000Base-T (C0) PCI Express, CentOS 6.8 y Java Versión 1.8.0\_80.

El conjunto total de parámetros usados se muestra en la Tabla I.

## V. RESULTADOS

Para calcular la calidad de los FPs obtenidos en cada configuración se han utilizado diferentes métricas, explicadas anteriormente. Como el HV requiere que se calcule un punto

de referencia, hemos elegido el valor (1,9) ya que ninguna de las soluciones existentes en todos los frentes obtenidas durante todas las ejecuciones están dominadas por él.

Se ha realizado una prueba de significación de Kruskal-Wallis a las métricas de todas las ejecuciones de las configuraciones, ya que la prueba de Kolmogorov-Smirnov detectó distribuciones no normales. Los resultados medios de cada configuración se muestran en la Tabla II. Como se explicó anteriormente, cuando  $P = 8$  los resultados de A son equivalentes a los obtenidos por D (porque  $c = 0$ ), y cuando  $P = 16$  son equivalentes a S ( $c = 1$ ). Nos referimos a esta equivalencia con la palabra *Equiv-* en las tablas.

Los resultados muestran que la división del cromosoma produce una mejora en todos los indicadores de calidad utilizando la versión automática (A) (Tabla II), superando incluso los métodos solapado (S) y disjunto (D). Por lo tanto, existe algún tipo de punto límite en la longitud de los cromosomas donde un método será preferible a otro, además de depender del número de islas y del tamaño de la población.

Esto puede explicarse comparando el número de soluciones no dominadas de cada frente y el número medio de generaciones (Tabla III). Aumentar el número de islas implica más generaciones con todos los métodos (lógicamente, ya que hay menos individuos en cada isla). Pero también, los métodos ASO se acercan al número de generaciones con la *baseline* al aumentar el número de islas. Sin embargo el tiempo de



#Island	HV				Spread				IGD			
	B	D	S	A	B	D	S	A	B	D	S	A
ZDT1												
8	0.891	<b>0.953</b>	0.937	Equiv-D	<b>0.681</b>	<b>0.635</b> B	0.661 D	Equiv-D	0.015	<b>0.002</b>	0.005	Equiv-D
16	0.884	0.850	<b>0.942</b>	Equiv-S	<b>0.705</b>	0.908	<b>0.670</b> B	Equiv-S	0.016	0.022	<b>0.004</b>	Equiv-S
32	0.851	0.674	0.859 B	<b>0.900</b>	<b>0.754</b>	0.868	0.826 D	<b>0.763</b> B	0.023	0.062	0.020 B	<b>0.012</b>
64	<b>0.800</b>	0.608	0.697	<b>0.824</b> B	<b>0.808</b>	0.880	<b>0.861</b> B	<b>0.823</b> B	0.033	0.078	0.056	<b>0.027</b>
128	0.735	0.582	0.613	<b>0.745</b>	<b>0.841</b>	0.888	0.878 D	0.865 S	0.047	0.084	0.075	<b>0.043</b>
ZDT2												
8	0.832	<b>0.895</b>	0.869	Equiv-D	<b>0.849</b>	<b>0.886</b> B	0.853 D	Equiv-D	0.023	<b>0.006</b>	0.013	Equiv-D
16	0.831	0.833 B	<b>0.884</b>	Equiv-S	<b>0.810</b>	1.001	<b>0.802</b> B	Equiv-S	0.023	0.022 B	<b>0.009</b>	Equiv-S
32	0.800	0.628	0.800 B	<b>0.817</b>	<b>0.848</b>	0.974	0.983 D	0.908	0.031	0.082	0.032 B	<b>0.027</b>
64	<b>0.729</b>	0.491	0.623	0.716	<b>0.909</b>	0.967	0.979 D	<b>0.997</b> BD	<b>0.052</b>	0.121	0.084	<b>0.055</b> B
128	<b>0.630</b>	0.441	0.500	<b>0.614</b> B	<b>0.957</b>	0.989	0.978 D	<b>0.994</b> BS	<b>0.080</b>	0.136	0.119	<b>0.085</b> B
ZDT3												
8	0.917	<b>0.971</b>	0.960	Equiv-D	<b>0.843</b>	<b>0.854</b> B	0.868 D	Equiv-D	0.009	<b>0.001</b>	0.004	Equiv-D
16	0.911	0.876 B	<b>0.963</b>	Equiv-S	<b>0.864</b>	0.899 B	<b>0.837</b> B	Equiv-S	0.010	0.014	<b>0.003</b>	Equiv-S
32	0.884	0.710	0.883 B	<b>0.931</b>	<b>0.856</b>	<b>0.870</b> B	<b>0.842</b> B	<b>0.842</b> BDS	0.013	0.032	0.013 B	<b>0.008</b>
64	0.828	0.645	0.728	<b>0.854</b>	<b>0.878</b>	<b>0.896</b> B	<b>0.871</b> BD	<b>0.873</b> BDS	<b>0.019</b>	0.040	0.030	<b>0.016</b> B
128	<b>0.770</b>	0.620	0.651	<b>0.773</b> B	<b>0.887</b>	<b>0.901</b> B	<b>0.890</b> BD	<b>0.885</b> BDS	<b>0.026</b>	0.043	0.039	<b>0.025</b> B
ZDT6												
8	0.271	<b>0.398</b>	0.323	Equiv-D	<b>0.982</b>	<b>0.982</b> B	0.994	Equiv-D	0.171	<b>0.115</b>	0.149	Equiv-D
16	0.275	0.295 B	<b>0.354</b>	Equiv-S	<b>0.981</b>	<b>0.970</b> B	1.006	Equiv-S	0.170	0.161 B	<b>0.136</b>	Equiv-S
32	0.239	0.123	0.240	<b>0.254</b>	<b>0.989</b>	<b>0.991</b> B	<b>0.982</b> BD	<b>0.999</b> BD	0.186	0.235	<b>0.185</b> B	<b>0.179</b>
64	<b>0.184</b>	0.068	0.125	<b>0.178</b> B	<b>0.985</b>	<b>0.982</b> B	<b>0.992</b> B	<b>0.995</b> BS	<b>0.209</b>	0.259	0.235	0.212
128	<b>0.128</b>	0.051	0.071	<b>0.124</b> B	<b>0.991</b>	<b>0.992</b> B	<b>0.988</b> BD	1.003	<b>0.233</b>	0.266	0.257	<b>0.235</b> B

Tabla II

MÉTRICAS DE CALIDAD MEDIA OBTENIDAS DESPUÉS DE 30 EJECUCIONES POR CONFIGURACIÓN, PARA LOS 4 MÉTODOS COMPARADOS: *baseline* (B), DISJUNTO (D), SOLAPADO (S) Y SOLAPADO AUTOMÁTICO (A). LOS ACRÓNIMOS QUE APARECEN JUNTO A LOS VALORES INDICAN QUE NO HAY DIFERENCIAS SIGNIFICATIVAS CON RESPECTO A ESE MÉTODO PARA ESE VALOR. LOS MEJORES VALORES ESTÁN MARCADOS EN NEGRITA. EQUIV-X IMPLICA QUE EL VALOR ES EL MISMO QUE EL DE EJECUTAR X, YA QUE AMBAS CONFIGURACIONES SERÍAN IGUALES.

#Island	Average solutions per front				Generations			
	B	D	S	A	B	D	S	A
ZDT1								
8	137.733	47.167	119.933 B	Equiv-D	175.067	225.667	207.933	Equiv-D
16	92.633	38.233	47.533 D	Equiv-S	204.867	238.533	232.900	Equiv-S
32	56.167	41.167	28.667	32.567 S	225.433	243.833	242.533	242.000 S
64	50.900	49.667 B	35.600	25.367	236.500	245.967	245.700	244.033 D
128	45.767	64.933	44.167 B	31.867	242.800	247.000	247.000 D	245.733
ZDT2								
8	64.267	22.733	56.867 B	Equiv-D	175.633	226.000	208.100	Equiv-D
16	52.300	10.733	20.067 D	Equiv-S	205.033	238.867	233.100	Equiv-S
32	34.400	10.367	10.433 D	17.900 S	225.600	244.267	242.633	242.000 S
64	24.600	10.900	9.267 D	12.867 DS	236.700	246.000	245.767	244.033 D
128	18.667	17.833 B	10.367	12.933 S	243.367	247.000	247.000 d	245.833
ZDT3								
8	163.767	83.367	119.467	Equiv-D	176.533	226.400	207.700	Equiv-D
16	108.467	49.433	47.700 D	Equiv-S	205.333	238.467	232.933	Equiv-S
32	72.133	44.333	31.833	36.533 S	225.100	243.900	242.433	242.000 S
64	54.867	57.600 B	40.633	29.300	236.333	245.933	245.733	244.000 D
128	50.600	72.133	49.033 B	34.933	243.200	247.000	247.000 D	245.833
ZDT6								
8	22.133	13.833	14.433 D	Equiv-D	175.733	226.100	207.767	Equiv-D
16	20.767	15.867	13.300 D	Equiv-S	205.033	238.433	232.933	Equiv-S
32	22.600	10.700	10.033 D	11.967 DS	225.833	243.667	242.500	242.000 S
64	19.033	11.267	10.533 D	10.567 DS	236.433	245.900	245.833	244.000 D
128	15.800	24.500	11.600	12.233 DS	243.800	247.000	247.000 D	245.533

Tabla III

PROMEDIO DE GENERACIONES Y PROMEDIO DE SOLUCIONES POR FRENTE, OBTENIDOS DESPUÉS DE 30 EJECUCIONES POR CONFIGURACIÓN, PARA LOS 4 MÉTODOS COMPARADOS: *baseline* (B), DISJUNTO (D), SOLAPADO (S) Y SOLAPADO AUTOMÁTICO (A). LOS ACRÓNIMOS QUE APARECEN JUNTO A LOS VALORES INDICAN QUE NO HAY DIFERENCIAS SIGNIFICATIVAS CON RESPECTO A ESE MÉTODO PARA ESE VALOR. EQUIV-X IMPLICA QUE EL VALOR ES EL MISMO QUE EL DE EJECUTAR X, YA QUE AMBAS CONFIGURACIONES SERÍAN IGUALES.

migración es lo suficientemente grande como para no mejorar el número de generaciones con respecto a la *baseline*, incluso en el menor número de islas. Por lo tanto, más generaciones no significan necesariamente mejorar la solución del FP global, sino centrarse en diferentes elementos del cromosoma. Como se ha dicho anteriormente, cada isla desconoce los FPs de las otras islas, y están tratando de optimizar sus soluciones independientemente. Con respecto al número promedio de soluciones por frente, hay una clara diferencia con la *baseline*, donde este valor es en la mayoría de los casos, menos de la mitad. El número de soluciones no dominadas también implica un mejor indicador de Spread, donde la *baseline* obtiene mejores (o no significativamente diferentes) valores

en la mayoría de las configuraciones comparadas.

## VI. CONCLUSIONES

Los problemas que requieren un alto rendimiento y que tratan con un gran número de variables de decisión pueden aprovecharse de la división del espacio de decisión que proporcionan los algoritmos paralelos y distribuidos. Esto se puede hacer en dMOEAs mediante la aplicación selectiva de operadores (ASO), es decir, dividiendo el cromosoma en diferentes partes, cada una modificada por una isla diferente. Este trabajo compara un NSGA-II distribuido, como *baseline*, con tres estrategias diferentes para separar el cromosoma (partes disjuntas o solapadas), utilizando distintos números de islas. Los resultados muestran que estos métodos pueden lograr

métricas de mejor calidad que el *baseline* en la misma cantidad de tiempo.

Los resultados obtenidos también muestran que al aumentar el número de islas, el método de solapamiento automático (A) mejora significativamente los resultados con respecto a los métodos disjuncto y solapado. El estudio de este factor con más tipos de problemas y nuevas configuraciones del tamaño de la población y la longitud de los cromosomas puede abordarse en el futuro. Por ejemplo, comparar diferentes maneras de calcular  $c$  usando funciones lineales, logarítmicas o exponenciales dependiendo del tamaño de la población, número de islas, tamaño del cromosoma, u otros valores. Además, se podría realizar un análisis de la diversidad de los individuos de cada isla durante la ejecución del algoritmo para comprender su influencia en los resultados.

Asimismo, podrían utilizarse implementaciones más distribuidas en varios sistemas (como GPUs o clusters heterogéneos) con diferentes cantidades de islas/procesadores para realizar un estudio de escalabilidad de los diferentes métodos, siendo el tiempo de transmisión entre islas un tema relevante a tratar. También pueden compararse otros MOEAs disponibles en la literatura, como SPEA o MOEA/D. Además, podrían utilizarse otros benchmarks y problemas reales para validar este enfoque.

#### REFERENCIAS

- [1] A. M. Mora, P. García-Sánchez, J. J. Merelo-Guervós, and P. A. Castillo, "Pareto-based multi-colony multi-objective ant colony optimization algorithms: an island model proposal," *Soft Comput.*, vol. 17, no. 7, pp. 1175–1207, 2013.
- [2] F. Luna and E. Alba, "Parallel multiobjective evolutionary algorithms," in *Springer Handbook of Computational Intelligence*, J. Kacprzyk and W. Pedrycz, Eds. Springer, 2015, pp. 1017–1031.
- [3] A. Mukhopadhyay, U. Maulik, S. Bandyopadhyay, and C. A. C. Coello, "A survey of multiobjective evolutionary algorithms for data mining: Part I," *IEEE T. Evolut. Comput.*, vol. 18, no. 1, pp. 4–19, 2014.
- [4] A. E. Eiben and J. E. Smith, *Introduction to Evolutionary Computing*, ser. Natural Computing Series. Springer, 2015.
- [5] E.-G. Talbi, "A unified view of parallel multi-objective evolutionary algorithms," *J. Parallel Distrib. Comput.*, pp.–, 2018, in press. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S074373151830279X>
- [6] E. Alba, G. Luque, and S. Nesmachnow, "Parallel metaheuristics: recent advances and new trends," *Int. T. Oper. Res.*, vol. 20, no. 1, pp. 1–48, 2013.
- [7] Y. Gong, W. Chen, Z. Zhan, J. Zhang, Y. Li, Q. Zhang, and J. Li, "Distributed evolutionary algorithms and their models: A survey of the state-of-the-art," *Appl. Soft Comput.*, vol. 34, pp. 286–300, 2015.
- [8] E. Alba and M. Tomassini, "Parallelism and evolutionary algorithms," *IEEE Trans. Evolutionary Computation*, vol. 6, no. 5, pp. 443–462, 2002.
- [9] J. Branke, H. Schmeck, K. Deb, and R. S. Maheshwar, "Parallelizing multi-objective evolutionary algorithms: cone separation," in *Proceedings of the IEEE Congress on Evolutionary Computation, CEC 2004, 19-23 June 2004, Portland, OR, USA*. IEEE, 2004, pp. 1952–1957.
- [10] D. Kimovski, J. Ortega, A. Ortiz, and R. Baños, "Parallel alternatives for evolutionary multi-objective optimization in unsupervised feature selection," *Expert Syst. Appl.*, vol. 42, no. 9, pp. 4239–4252, 2015.
- [11] P. García-Sánchez, J. Ortega, J. González, P. A. Castillo, and J. J. Merelo, "Addressing high dimensional multi-objective optimization problems by coevolutionary islands with overlapping search spaces," in *Applications of Evolutionary Computation - 19th European Conference, EvoApplications 2016, Porto, Portugal, March 30 - April 1, 2016, Proceedings, Part II*, ser. Lecture Notes in Computer Science, G. Squillero and P. Burelli, Eds., vol. 9598. Springer, 2016, pp. 107–117.
- [12] E. Talbi, S. Mostaghim, T. Okabe, H. Ishibuchi, G. Rudolph, and C. A. C. Coello, "Parallel approaches for multiobjective optimization," in *Multiobjective Optimization, Interactive and Evolutionary Approaches [outcome of Dagstuhl seminars]*, ser. Lecture Notes in Computer Science, J. Branke, K. Deb, K. Miettinen, and R. Slowinski, Eds., vol. 5252. Springer, 2008, pp. 349–372.
- [13] A. J. Nebro and J. J. Durillo, "A study of the parallelization of the multi-objective metaheuristic MOEA/D," in *Learning and Intelligent Optimization, 4th International Conference, LION 4, Venice, Italy, January 18-22, 2010. Selected Papers*, ser. Lecture Notes in Computer Science, C. Blum and R. Battiti, Eds., vol. 6073. Springer, 2010, pp. 303–317.
- [14] K. Deb, P. Zope, and A. Jain, "Distributed computing of Pareto-optimal solutions with evolutionary algorithms," in *Evolutionary Multi-Criterion Optimization, Second International Conference, EMO 2003, Faro, Portugal, April 8-11, 2003, Proceedings*, ser. Lecture Notes in Computer Science, C. M. Fonseca, P. J. Fleming, E. Zitzler, K. Deb, and L. Thiele, Eds., vol. 2632. Springer, 2003, pp. 534–549.
- [15] W. Zhi-xin and G. Ju, "A parallel genetic algorithm in multi-objective optimization," in *Control and Decision Conference, 2009. CCDC '09. Chinese*, June 2009, pp. 3497–3501.
- [16] N. Xiao and M. P. Armstrong, "A specialized island model and its application in multiobjective optimization," in *Genetic and Evolutionary Computation - GECCO 2003, Genetic and Evolutionary Computation Conference, Chicago, IL, USA, July 12-16, 2003. Proceedings, Part II*, ser. Lecture Notes in Computer Science, E. Cantú-Paz, J. A. Foster, K. Deb, L. Davis, R. Roy, U. O'Reilly, H. Beyer, R. K. Standish, G. Kendall, S. W. Wilson, M. Harman, J. Wegener, D. Dasgupta, M. A. Potter, A. C. Schultz, K. A. Dowland, N. Jonoska, and J. F. Miller, Eds., vol. 2724. Springer, 2003, pp. 1530–1540.
- [17] M. Märtens and D. Izzo, "The asynchronous island model and NSGA-II: study of a new migration operator and its performance," in *Genetic and Evolutionary Computation Conference, GECCO '13, Amsterdam, The Netherlands, July 6-10, 2013*, C. Blum and E. Alba, Eds. ACM, 2013, pp. 1173–1180.
- [18] B. Dorronsoro, G. Danoy, A. J. Nebro, and P. Bouvry, "Achieving super-linear performance in parallel multi-objective evolutionary algorithms by means of cooperative coevolution," *Computers & OR*, vol. 40, no. 6, pp. 1552–1563, 2013.
- [19] A. Atashpendar, B. Dorronsoro, G. Danoy, and P. Bouvry, "A scalable parallel cooperative coevolutionary PSO algorithm for multi-objective optimization," *J. Parallel Distrib. Comput.*, vol. 112, pp. 111–125, 2018.
- [20] E. Zitzler, K. Deb, and L. Thiele, "Comparison of Multiobjective Evolutionary Algorithms: Empirical Results," *Evol. Comput.*, vol. 8, no. 2, pp. 173–195, 2000.
- [21] E. Alba and G. Luque, "Evaluation of parallel metaheuristics," in *Empirical Methods for the Analysis of Algorithms, Workshop EMOA 2006, Proceedings*, L. Paquete, M. Chiarandini, and D. Basso, Eds., Reykjavik, Iceland, 2006, pp. 9–14.
- [22] S. Luke *et al.*, "ECJ: A Java-based Evolutionary Computation and Genetic Programming Research System," 2009, available at <http://www.cs.umd.edu/projects/plus/ec/ecj>.



# Análisis de Diseños Paralelos Multiobjetivo y Políticas de Planificación en Biología Evolutiva

Sergio Santander-Jiménez

INESC-ID, IST, Universidade de Lisboa,  
Lisboa 1000-029, Portugal  
sergio.jimenez@tecnico.ulisboa.pt

Miguel A. Vega-Rodríguez

INTIA, Universidad de Extremadura,  
Cáceres 10003, España  
mavega@unex.es

Leonel Sousa

INESC-ID, IST, Universidade de Lisboa,  
Lisboa 1000-029, Portugal  
leonel.sousa@ist.utl.pt

**Resumen**—Las metaheurísticas paralelas representan una de las técnicas de mayor popularidad para abordar la resolución de problemas de optimización complejos. Sin embargo, una de las cuestiones principales que surgen al emplear estos métodos viene dada por la aparición potencial de problemas de desequilibrio de carga. De hecho, la complejidad de los problemas de optimización actuales obliga a la adopción de múltiples estrategias de búsqueda condicionales dentro de la metaheurística, lo cual incide en el impacto que implica el desequilibrio de carga en el rendimiento paralelo. Este trabajo analiza diferentes políticas de planificación y diseños algorítmicos para abordar el desequilibrio de carga en la metaheurística *Multiobjective Shuffled Frog-Leaping Algorithm*. Tomando como caso de estudio un problema de biología evolutiva, la reconstrucción filogenética, abordamos la evaluación de tres políticas de planificación en el algoritmo original, así como una alternativa de diseño basada en el uso de contadores. Los resultados obtenidos en cuatro bases de datos reales dan cuenta de la influencia de las aproximaciones estudiadas en los tiempos de sobrecarga, destacando los beneficios de integrar políticas dinámicas y diseños que respeten las mecánicas del algoritmo.

**Index Terms**—Biología evolutiva, desequilibrio de carga, computación paralela, metaheurísticas multiobjetivo

## I. INTRODUCCIÓN

La resolución eficiente de problemas de optimización se ha convertido en una de las líneas de investigación predominantes en multitud de dominios científicos. En contextos reales, es obligatorio el diseño de aproximaciones algorítmicas innovadoras para cumplir los requisitos de calidad de solución y, al mismo tiempo, lidiar con la naturaleza NP-completa de estos problemas. Sin embargo, la dificultad de estos procesos de optimización continúa creciendo con la adopción de formulaciones más realistas, escenarios *Big Data*, múltiples funciones objetivo, etc. Así, es habitual la presencia de tiempos de ejecución elevados que resultan inasumibles incluso al emplear técnicas estocásticas de resolución. Las metaheurísticas paralelas han demostrado aplicabilidad potencial para lidiar con estas cuestiones, obteniendo resultados significativos [1].

A pesar de la naturaleza intrínsecamente paralela de las metaheurísticas basadas en población, estos métodos pueden

verse afectados por dos fuentes principales de desequilibrio de carga. Al nivel del diseño metaheurístico, los operadores de búsqueda pueden mostrar distintos requisitos temporales, hecho que puede volverse más remarcable en situaciones de cambio de contexto de explotación a exploración (o viceversa). Al nivel de implementación del problema, las soluciones generadas pueden mostrar características divergentes que influyen, por ejemplo, en los cálculos efectuados en las funciones objetivo, dando lugar a tiempos de evaluación no homogéneos. Estas cuestiones implican un aumento de la sobrecarga y, consecuentemente, un empeoramiento del rendimiento paralelo.

Así, las metaheurísticas paralelas deben considerar este tipo de factores para conseguir una explotación precisa de los recursos hardware. Este trabajo se focaliza en el análisis de distintas políticas de planificación y diseños para abordar problemas de desequilibrio de carga. Adoptamos como caso de estudio un problema de biología evolutiva: la inferencia de relaciones ancestrales entre especies [2]. En escenario mono-objetivo, existen propuestas como IQ-TREE [3] y GARLI [4] que han dado cuenta de los beneficios de emplear computación de altas prestaciones y métodos bioinspirados de búsqueda en este problema. Las aproximaciones multiobjetivo también representan una tendencia significativa en el caso de datos de ADN [5], al contribuir potencialmente a la resolución de problemas de incongruencia en contextos reales.

Abordaremos este problema biológico desde la perspectiva multiobjetivo, usando una metaheurística basada en población denominada *Multiobjective Shuffled Frog-Leaping Algorithm* (MO-SFLA) [6]. Bajo implementaciones MPI+OpenMP, examinaremos el impacto de distintas políticas de planificación (estática, guiada y dinámica) en el rendimiento paralelo del diseño algorítmico original, así como diseños alternativos de la aproximación. El análisis planteado será efectuado sobre cuatro instancias reales del problema basadas en secuencias de proteínas, las cuales presentan un nivel superior de complejidad con respecto a otros tipos de datos biológicos [7]. La bondad de los resultados obtenidos será estudiada mediante comparativas con otros métodos del estado del arte.

Este artículo se organiza del siguiente modo. La Sección II detalla la formulación del problema estudiado. La Sección III describe diseños y políticas de planificación para MO-SFLA, examinándose resultados en la Sección IV. Finalmente, la Sección V destaca conclusiones y líneas futuras de trabajo.

Este trabajo ha sido parcialmente financiado por la AEI (Agencia Estatal de Investigación, España) y el FEDER (Fondo Europeo de Desarrollo Regional, UE), bajo el proyecto TIN2016-76259-P (proyecto PROTEIN), así como por la FCT (Fundação para a Ciência e a Tecnologia, Portugal) bajo los proyectos UID/CEC/50021/2013 y LISBOA-01-0145-FEDER-031901 (PTDC/CCI-COM/31901/2017, HiPerBio). Sergio Santander-Jiménez agradece a la FCT el soporte recibido a través del contrato postdoctoral SFRH/BPD/119220/2016.

## II. FORMULACIÓN DEL PROBLEMA

La inferencia de relaciones ancestrales entre organismos representa uno de los problemas más importantes en biología evolutiva [2]. Dicho problema involucra el estudio de un alineamiento múltiple de secuencias de tamaño  $N \times M$  (donde  $N$  es el número de secuencias y  $M$  la longitud de secuencia), el cual es procesado para identificar patrones de divergencia y similitud. Esta información es utilizada para inferir organismos ancestrales hipotéticos y definir el curso de la evolución a través de una estructura arborescente, conocida como árbol filogenético  $T = (V, E)$ . En particular, los nodos internos del conjunto de nodos  $V$  describen los ancestros potenciales cuya evolución dio lugar a los organismos caracterizados en el alineamiento de entrada, organismos que se localizan en los nodos hoja. La definición de relaciones evolutivas se efectúa a través del conjunto de ramas  $E$ , donde se definen los enlaces ancestro-descendiente entre nodos emparentados.

La aplicación de procedimientos de optimización en este problema tienen por objeto identificar el árbol filogenético que maximice o minimice un determinado criterio de optimalidad biológico, lo cual implica la exploración de un espacio de filogenias  $S$ . La principal cuestión que surge en este contexto viene dada por el crecimiento exponencial de  $S$  con el número de secuencias  $N$ , definiéndose el número de posibles soluciones candidatas en  $S$  de acuerdo al doble factorial  $(2N - 5)!!$  [2]. Otros factores, tales como la longitud de secuencia  $M$ , el tipo de datos contenido en el alineamiento (por ejemplo, aminoácidos) y la consideración conjunta de múltiples criterios de optimalidad, contribuyen al elevado coste computacional del problema. Todo ello impide la aplicación de aproximaciones serie tradicionales.

En este artículo, afrontamos estas cuestiones mediante aproximaciones metaheurísticas paralelas. La formulación adoptada del problema involucra la optimización de dos funciones objetivo: parsimonia y verosimilitud. Por un lado, la parsimonia cuantifica el número de cambios observados entre las secuencias de nodos emparentados. El objetivo radica en inferir la hipótesis evolutiva más simple, dando prioridad a la solución  $T = (V, E)$  que minimice el número de cambios medidos a través del valor de parsimonia  $P(T)$  [2]:

$$P(T) = \sum_{i=1}^M \sum_{(u,v) \in E} C(u_i, v_i), \quad (1)$$

donde  $(u, v) \in E$  representa la rama de la topología que conecta dos nodos  $u, v \in V$ ,  $u_i$  y  $v_i$  son los valores de estado del  $i$ -ésimo carácter de las secuencias correspondientes a  $u$  y  $v$ , y  $C(u_i, v_i)$  indica las mutaciones observadas entre  $u$  y  $v$  ( $C(u_i, v_i)=1$  si  $u_i \neq v_i$  y  $C(u_i, v_i)=0$  en caso contrario).

Por su parte, la función de verosimilitud establece una medida probabilística de la plausibilidad de que el árbol filogenético evaluado haya dado lugar efectivo a la diversidad observada en el alineamiento de entrada. Los cálculos de verosimilitud se realizan conforme a modelos de evolución que definen las probabilidades de observar mutaciones desde

cada posible valor de estado de carácter a cualquier otro. Bajo esta función, se da prioridad a la solución  $T = (V, E)$  que maximice el valor de verosimilitud  $L(T)$  [2]:

$$L(T) = \prod_{i=1}^M \sum_{x,y \in \Lambda} \pi_x [P_{xy}(t_{ru}) L_p(u_i = y)] \times [P_{xy}(t_{rv}) L_p(v_i = y)], \quad (2)$$

donde  $\Lambda$  es el alfabeto de estados de carácter (aminoácidos en el caso de secuencias de proteínas),  $\pi_x$  la probabilidad estacionaria de observar el valor de estado  $x$ ,  $r \in V$  la raíz de  $T$  con hijos  $u, v \in V$ ,  $P_{xy}(t)$  la probabilidad de mutación de  $x$  a otro estado  $y$  en un tiempo  $t$  (siendo  $t_{ru}$  y  $t_{rv}$  la longitud de las ramas  $(r, u), (r, v) \in E$ ), y  $L_p(u_i = y)$ ,  $L_p(v_i = y)$  las verosimilitudes parciales de observar  $y$  en  $u_i$  y  $v_i$ .

## III. DESCRIPCIÓN DE MÉTODOS

MO-SFLA es una metaheurística que integra mecanismos multiobjetivo en el método *frog leaping optimization* [8]. En cada iteración, los *popSize* individuos que conforman la población son ordenados (según sus valores de fitness) y distribuidos uniformemente en  $m$  particiones denominadas memplexes. Cada memplex contiene  $n=popSize/m$  individuos, cuya evolución se produce separadamente durante  $n_l$  pasos de aprendizaje. Una vez todos los memplexes han sido procesados, son combinados para permitir una compartición de información entre todos los memplexes, actualizando la población para la siguiente generación.

Para la adaptación al problema abordado, MO-SFLA incluye una representación del individuo basada en matrices de distancia filogenéticas. Una solución candidata vendrá codificada por una matriz simétrica  $\delta$  que contiene en cada entrada  $\delta[x, y]$  la distancia evolutiva entre los organismos  $x$  e  $y$ . El mapeo de soluciones desde este espacio de decisión matricial al espacio de filogenias se lleva a cabo mediante el método de reconstrucción de árboles filogenéticos BIONJ [2]. La etapa de inicialización de la población considerará matrices de distancia calculadas a partir de topologías filogenéticas iniciales generadas mediante técnicas de *bootstrapping* [2].

El Pseudocódigo 1 detalla el diseño original de MO-SFLA, el cual realiza el proceso de optimización hasta que un determinado criterio de parada (en nuestro caso, un máximo de evaluaciones) es satisfecho. Al comienzo de cada generación, los individuos de la población son ordenados según su calidad multiobjetivo (línea 7 en el Pseudocódigo 1), manteniendo las *popSize* soluciones más prometedoras conforme a sus valores de ranking Pareto (*fast non-dominated sort*) y densidad (distancia de *crowding*) [9]. Tras la ordenación, se definen los memplexes mediante la distribución de individuos de manera iterativa, asignando el individuo  $i$ -ésimo al memplex  $i \% m$ .

La generación de nuevas soluciones candidatas dentro de cada memplex se realiza mediante la definición de distintos operadores de búsqueda (líneas 17-26), que son aplicados según el estado actual del proceso de optimización. Dado un memplex  $Mem_i$ , generamos una nueva solución  $P'_{new}$  conforme a la siguiente formulación:



### Pseudocódigo 1 MO-SFLA Paralelo

```

1: MPI_Init /* inicializando proceso MPI #i */
2: #pragma omp parallel num_threads (num_hilos)
3: mientras ! criterio de parada (maxEval) hacer
4:   /* Definición y asignación de memplexes */
5:   #pragma omp single
6:   si proceso maestro entonces
7:     {Mem1 ... Memm} ← Ordenación y Distribución (P, popSize)
8:     BestGlobal ← Identificar Mejor Global ({Mem1 ... Memm})
9:     /* ∀i : i = 2 a m */
10:    MPI_Send (Memi, n, i), MPI_Send (BestGlobal, 1, i)
11:   si no
12:     MPI_Recv (Memi, n, master_id), MPI_Recv (BestGlobal, 1, master_id)
13:   fin si
14:   BestLocal ← Identificar Mejor Local (Memi)
15:   /* Tareas paralelas: evolución del memplex asignado */
16:   #pragma omp for
17:   para j = 1 to ni hacer
18:     P'new ← Aprendizaje Mejor Local (BestLocal, Memi(n-j))
19:     si ! P'new > Memi(n-j) entonces
20:       P'new ← Aprendizaje Mejor Global (BestGlobal, Memi(n-j))
21:     si ! P'new > Memi(n-j) entonces
22:       P'new ← Búsqueda Local (Memi(n-j))
23:     fin si
24:   fin si
25:   Memi(n-j) ← P'new
26: fin para
27: /* Entrega de resultados */
28: #pragma omp single
29: si proceso maestro entonces
30:   /* ∀i : i = 2 a m */
31:   MPI_Recv (Memi, n, i)
32:   P ← Mezclar Memplexes (P, {Mem1 ... Memm})
33:   ParetoFront ← Actualizar Frente de Pareto (P)
34: si no
35:   MPI_Send (Memi, n, master_id)
36: fin si
37: fin mientras
38: MPI_Finalize /* finalizando proceso MPI #i */

```

$$D_{xy} = rand() \cdot (Ref.\delta[x, y] - Mem_{ij}.\delta[x, y]), \quad (3)$$

$$P'_{new}.\delta[x, y] = Mem_{ij}.\delta[x, y] + D_{xy}, \quad (4)$$

donde  $rand()$  es un número aleatorio de una distribución uniforme en el rango  $[0, 1]$  y  $Mem_{ij}$  el individuo en  $Mem_i$  procesado en el paso de aprendizaje  $j$ .  $Ref$  representa una solución que es tomada como referencia durante este proceso. Inicialmente, se toma como  $Ref$  el mejor individuo local de  $Mem_i$  (línea 18). En caso de que la solución resultante  $P'_{new}$  no mejore a  $Mem_{ij}$ , se repite el proceso anterior tomando como  $Ref$  el mejor individuo global de toda la población (línea 20). Si sigue sin observarse mejora, se aplica una búsqueda local basada en los operadores topológicos *nearest neighbour interchange* y *subtree pruning and regrafting* [2] (línea 22).

Al final de la generación (líneas 32, 33), los memplexes son reunificados para actualizar la estructura de la población, la cual es usada a su vez para identificar soluciones no dominadas y así almacenarlas en la estructura *ParetoFront*. Al satisfacerse el criterio de parada, dicha estructura contendrá las soluciones no dominadas encontradas a lo largo de la ejecución, representando la salida del algoritmo.

#### III-A. Diseños Paralelos y Políticas de Planificación

MO-SFLA presenta dos características clave que hacen a esta metaheurística adecuada para su ejecución en clusters

multicore: 1) el procesamiento de memplexes puede efectuarse de manera independiente de una memplex a otro; y 2) la generación de soluciones candidatas dentro del mismo memplex no presenta dependencias de un paso de aprendizaje (iteración del bucle) a otro. Estos dos niveles son apropiados para su explotación mediante MPI+OpenMP [10], [11].

En cada generación, un proceso maestro se encargará inicialmente de la gestión de la población y la definición de memplexes, distribuyendo adecuadamente los individuos. Los memplexes resultantes serán asignados a distintos procesos trabajadores mediante las funciones MPI MPI\_Send y MPI\_Recv (línea 10 en el Pseudocódigo 1 para el lado emisor - maestro, y línea 12 para el lado receptor - trabajador). Concluida la comunicación, cada proceso (incluyendo el maestro) realizará el procesamiento de los memplexes asignados (líneas 15-26), usando la directiva #pragma omp for para distribuir las iteraciones del bucle entre los hilos de ejecución. Terminado el procesamiento de memplexes, los resultados obtenidos son comunicados mediante funciones MPI al proceso maestro (líneas 31 -maestro, y 35 - trabajador), efectuándose entonces las tareas finales de la generación.

En este diseño, los procesos se ven afectados por distintas fuentes de desequilibrio de carga. En primer lugar, la metaheurística plantea hasta tres estrategias de búsqueda diferentes que pueden ser ejecutadas en una misma iteración del bucle paralelo definido en la línea 17. Así, cada iteración puede implicar un número variable de operaciones en conformidad con el éxito de las estrategias aplicadas. Además, la generación de una nueva solución candidata involucra dos mecanismos específicos del problema: la reconstrucción del árbol y el cómputo de las funciones objetivo. Estas operaciones se caracterizan no solo por el hecho de incluir cálculos computacionalmente costosos, sino también por presentar divergencias en tiempo de ejecución según las características de la solución candidata.

Para afrontar dichos problemas de desequilibrio de carga, consideraremos primero el uso de las políticas de planificación de bucles paralelos definidas en el estándar OpenMP. Concretamente, examinamos tres aproximaciones diferentes:

1. *Estática*. Las iteraciones son divididas en bloques que se asignan de manera estática a cada hilo en modo *round-robin* según el identificador de hilo. Dado que esto no permite la resolución de desequilibrios de carga potenciales (al tener cada hilo sus iteraciones asignadas a priori), usaremos esta política como punto de referencia.
2. *Dinámica*. En esta aproximación, los hilos solicitan gradualmente nuevas iteraciones al terminar las que han ido manejado previamente. Así, los hilos más rápidos pueden comenzar el procesamiento de nuevos bloques inmediatamente tras acabar su carga de trabajo inicial.
3. *Guiada*. De manera similar a la aproximación dinámica, la planificación guiada permite la asignación gradual de iteraciones a los hilos. Se asignan nuevas iteraciones mediante bloques de tamaño proporcional al número de iteraciones aún no asignadas dividido entre el número de hilos, reduciendo estos bloques de manera exponencial hasta un mínimo de 1 (configuración estándar).

**Pseudocódigo 2 MO-SFLA Paralelo Basado en Contadores**

```

1: MPI_Init /* inicializando proceso MPI #i */
2: #pragma omp parallel num_threads (num_hilos)
3: mientras ! criterio de parada (maxEval) hacer
4:     #pragma omp single
5:     BestGlobal, {Mem1 ... Memm} ← Gestionar Población (P, popSize)
6:     Asignación Memeplex-Proceso (BestGlobal, Memi, i) /*∀i : i = 2 a m*/
7:     BestLocal ← Identificar Mejor Local (Memi)
8:     #pragma omp for
9:     para j = 1 to ni hacer
10:        switch (Memi(n-j).counter)
11:            caso 0: P'new ← Aprendizaje Mejor Local (BestLocal, Memi(n-j))
12:            caso 1: P'new ← Aprendizaje Mejor Global (BestGlobal, Memi(n-j))
13:            caso 2: P'new ← Búsqueda Local (Memi(n-j))
14:        si P'new > Memi(n-j) || Memi(n-j).counter == 2 entonces
15:            Memi(n-j) ← P'new, Memi(n-j).counter ← 0
16:        si no
17:            Memi(n-j).counter ← Memi(n-j).counter + 1
18:        fin si
19:    fin para
20:    #pragma omp single
21:    Comunicación de Resultados (Memi, master_id) /*∀i : i = 2 a m*/
22:    P, ParetoFront ← Tareas Finales de la Generación (P, {Mem1 ... Memm})
23: fin mientras
24: MPI_Finalize /* finalizando proceso MPI #i */
    
```

Una alternativa a esta aproximación radica en la adaptación del diseño para que cada iteración del bucle de procesamiento de memplexes ejecute solo una de las estrategias de búsqueda definidas. Esta idea viene plasmada en el Pseudocódigo 2, la cual se basa en el empleo de contadores para medir el número de intentos en que un individuo de la población no ha sido mejorado. En función del valor de este contador, se decide la estrategia de búsqueda a ser aplicada sobre dicho individuo (líneas 10-13 del Pseudocódigo 2). Dado un individuo  $Mem_{ij}$ , un valor de 0 en su contador implicará la generación de la nueva solución empleando el mejor individuo local de  $Mem_i$ , mientras que un valor de 1 conllevará el empleo del mejor individuo global y un valor de 2 la búsqueda local. En caso de observarse mejora, el contador asociado será reinicializado y la solución almacenada en  $Mem_{ij}$  (línea 15). En caso contrario, la solución generada es descartada y el contador de  $Mem_{ij}$  incrementado (línea 17). De esta manera, en la siguiente generación el proceso trabajador efectuará un nuevo intento sobre  $Mem_{ij}$  considerando una estrategia de búsqueda diferente. Como en la versión original, se pueden emplear las políticas de planificación de OpenMP para complementar el mecanismo de balanceo basado en contadores.

**IV. RESULTADOS EXPERIMENTALES**

En esta sección abordamos la evaluación experimental de los diseños paralelos y políticas de planificación considerados para MO-SFLA. Para ello, examinaremos el rendimiento paralelo obtenido en cuatro bases de datos reales de proteínas, las cuales son descritas en la Tabla I. La experimentación fue efectuada sobre 4 nodos de cómputo de una infraestructura clúster con interconexión Gigabit Ethernet. Estos nodos están compuestos por procesadores AMD Opteron 6174 de 12 cores a 2,2GHZ (un total de 48 cores disponibles) con 12MB de memoria caché L3 y 16GB de RAM DDR3, Ubuntu 14.04LTS como sistema operativo y el compilador GCC 5.2.1.

De acuerdo a las características del clúster empleado y los estudios paramétricos efectuados, los parámetros de entrada

Tabla I  
CONJUNTOS DE DATOS DE PROTEÍNAS USADOS EN LA EXPERIMENTACIÓN

Instancia	$N$	$M$	Organismo	Modelo Evolutivo [2]
M88x3329	88	3329	Hongos termófilos [12]	LG+ $\Gamma$
M187x814	187	814	Hongos micorrícicos [13]	LG+ $\Gamma$
M260x1781	260	1781	Beta vulgaris [14]	JTT+ $\Gamma$
M355x1263	355	1263	Hemiascometocetos [15]	LG+ $\Gamma$

Tabla II  
COMPARATIVA PARALELA (SPEEDUPS SU Y EFICIENCIA EF)

M88x3329 ( $T_{serie} = 57111,63$ segundos)									
Cores	Estática		Dinámica		Guiada		Contadores		
	SU	EF (%)	SU	EF (%)	SU	EF (%)	SU	EF (%)	
8	6,93	86,59	<b>7,21</b>	<b>90,10</b>	7,09	88,65	<b>7,81</b>	<b>97,67</b>	
16	11,58	72,38	<b>13,53</b>	<b>84,57</b>	13,31	83,18	<b>14,94</b>	<b>93,38</b>	
32	19,10	59,69	<b>22,83</b>	<b>71,36</b>	22,34	69,82	<b>28,18</b>	<b>88,06</b>	
48	26,18	54,54	<b>28,88</b>	<b>60,17</b>	27,84	57,99	<b>39,86</b>	<b>83,04</b>	
M187x814 ( $T_{serie} = 44171,92$ segundos)									
8	6,16	77,06	<b>6,54</b>	<b>81,78</b>	6,46	80,74	<b>7,70</b>	<b>96,27</b>	
16	10,70	66,88	<b>12,18</b>	<b>76,12</b>	11,96	74,78	<b>14,75</b>	<b>92,19</b>	
32	18,58	58,06	<b>21,85</b>	<b>68,28</b>	20,99	65,60	<b>27,71</b>	<b>86,59</b>	
48	23,96	49,92	<b>28,33</b>	<b>59,03</b>	26,04	54,25	<b>39,66</b>	<b>82,63</b>	
M260x1781 ( $T_{serie} = 66748,33$ segundos)									
8	7,37	92,16	<b>7,69</b>	<b>96,18</b>	7,55	94,33	<b>7,86</b>	<b>98,28</b>	
16	12,75	79,69	<b>14,18</b>	<b>88,61</b>	13,70	85,61	<b>15,65</b>	<b>97,81</b>	
32	20,45	63,91	<b>23,29</b>	<b>72,78</b>	22,51	70,36	<b>29,20</b>	<b>91,25</b>	
48	26,36	54,92	<b>30,21</b>	<b>62,94</b>	27,90	58,11	<b>40,56</b>	<b>84,49</b>	
M355x1263 ( $T_{serie} = 96219,62$ segundos)									
8	6,79	84,90	<b>7,47</b>	<b>93,40</b>	7,22	90,21	<b>7,92</b>	<b>98,95</b>	
16	11,92	74,50	<b>13,76</b>	<b>86,03</b>	13,69	85,56	<b>15,68</b>	<b>98,00</b>	
32	21,96	68,63	<b>25,59</b>	<b>79,97</b>	23,77	74,28	<b>29,87</b>	<b>93,34</b>	
48	29,30	61,04	<b>32,97</b>	<b>68,69</b>	30,80	64,17	<b>42,63</b>	<b>88,82</b>	

de MO-SFLA fueron establecidos a los siguientes valores:  $popSize = 128$ ,  $m = 4$ ,  $n = 32$ ,  $n_i = 32$ ,  $maxEval = 10000$ .

**IV-A. Evaluación del Rendimiento Paralelo**

Con objeto de examinar el rendimiento paralelo, emplearemos las métricas paralelas de aceleración o *speedup* y eficiencia [11]. Consideraremos los resultados temporales medianos (procedentes de 11 ejecuciones independientes por experimento) obtenidos sobre distintos tamaños del sistema (8, 16, 32 y 48 cores). La Tabla II presenta los resultados observados, así como los tiempos de la versión serie de MO-SFLA  $T_{serie}$  usados como referencia en el cálculo de las métricas paralelas.

Centrándonos en primer lugar en los resultados del diseño original (columnas 2, 3 - versión estática, 4, 5 - dinámica, y 6, 7 - guiada), es posible observar el efecto del desequilibrio de carga en el rendimiento de la versión inicial estática. De hecho, la política estática no resulta adecuada para superar el umbral de 50% de eficiencia en el caso de instancias como M187x814 con 48 cores, lo cual sugiere una baja utilización de los recursos hardware disponibles. Por su parte, el empleo de políticas de planificación dinámica da lugar a una reducción considerable en la sobrecarga de la versión estática, reduciendo los tiempos de espera a nivel de hilos hasta un 33,6% (para la instancia M355x1263) y los de sincronización inter-proceso hasta un 45,4% (M187x814). Esto implica que, para el diseño original de MO-SFLA, la planificación dinámica consigue el

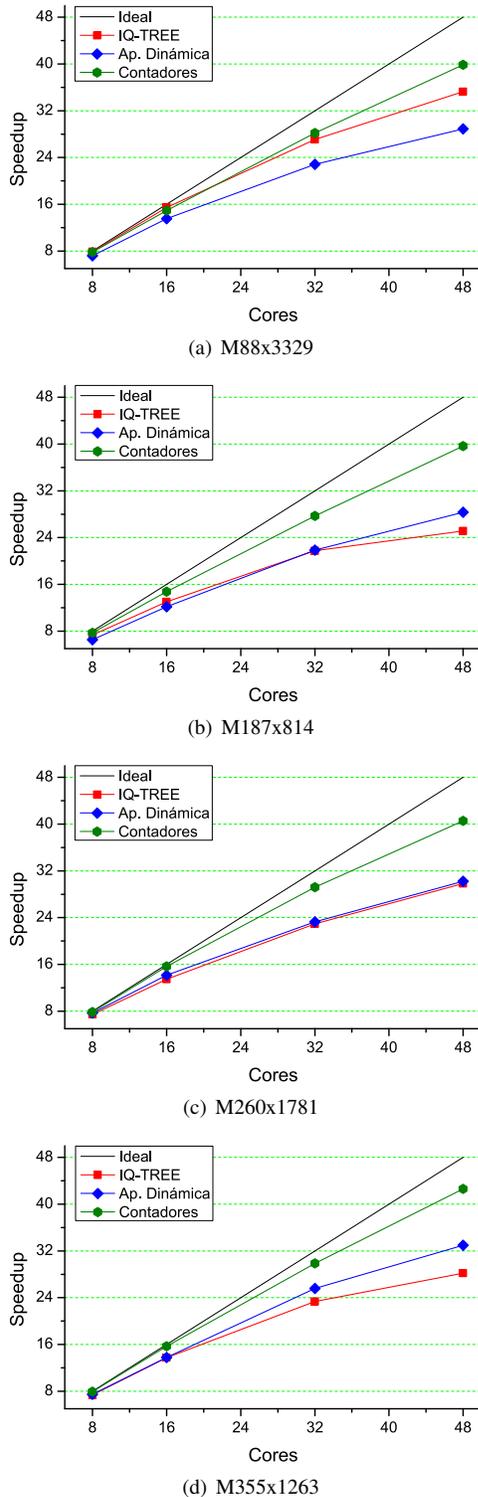


Figura 1. Comparativas de Rendimiento Paralelo (MO-SFLA Original Dinámico, MO-SFLA Basado en Contadores e IQ-TREE)

rendimiento paralelo más satisfactorio en la comparativa, con eficiencias medias de 90,4 % (8 cores), 83,8 % (16 cores), 73,1 % (32 cores) y 62,7 % (48 cores). En esta comparativa, la política guiada representa un escenario intermedio, con

eficiencias medias de 88,5 % (8 cores), 82,3 % (16 cores), 70,0 % (32 cores) y 58,6 % (48 cores). Con respecto a la versión estática, la planificación guiada reduce hasta un 13,7 % (M355x1263) los tiempos de espera entre hilos, así como hasta un 33,3 % (M187x814) la sincronización entre procesos. Sin embargo, estos resultados no igualan la calidad de la política dinámica, la cual representa la aproximación más adecuada en el contexto del diseño original de MO-SFLA.

Considerando estos resultados, hemos aplicado la política dinámica a su vez en el diseño basado en contadores de MO-SFLA. Los *speedups* y eficiencias obtenidos son mostrados en las columnas 8, 9 de la Tabla II. Conforme a estos resultados, el mecanismo alternativo estudiado consigue mejorar de manera significativa la escalabilidad paralela del diseño original, consiguiendo factores de aceleración medios de 7,8x (8 cores), 15,1x (16 cores), 28,7x (32 cores) y 40,7x (48 cores). A través de un mayor equilibrado de tareas en el bucle paralelo de procesamiento de memplexes, esta alternativa permite reducir los tiempos de espera entre hilos hasta un 72,1 % (M88x3329), dando lugar a una reducción de hasta 92,0 % (M187x814) en los tiempos de sincronización entre procesos. Como resultado, el diseño basado en contadores obtiene una eficiencia media de 84,7 % para 48 cores, representando una mejora notable con respecto al 62,7 % de la versión original dinámica.

Para validar la bondad de estos resultados, la Figura 1 presenta una comparativa de rendimiento paralelo entre el diseño original con planificación dinámica de MO-SFLA, el diseño basado en contadores, y la herramienta filogenética paralela IQ-TREE (la cual integra técnicas MPI+OpenMP) [3]. Estos resultados dan cuenta de que el diseño original dinámico obtiene una mejoría con respecto a IQ-TREE a partir de escenarios de 32 / 48 cores para M187x814, así como en M260x1781 y, especialmente, M355x1263. Por su parte, el diseño basado en contadores presenta las mejores propiedades de escalabilidad de la comparativa, mejorando de manera significativa los resultados de IQ-TREE en todos los escenarios de evaluación considerados. Todo ello redunda en la relevancia de la estrategia adoptada para minimizar problemas de balanceo de carga en el diseño algorítmico de MO-SFLA.

#### IV-B. Resultados Biológicos

A continuación abordamos la validación de calidad de solución del método, usando resultados medianos de 31 ejecuciones independientes por instancia. En primer lugar, examinaremos el rendimiento multiobjetivo mediante el empleo de la métrica de hipervolumen (usando los puntos de referencia definidos en [6]). En este contexto, es preciso señalar que, para este problema, no se observaron diferencias estadísticamente significativas entre las muestras de hipervolumen de la versión original de MO-SFLA y la versión basada en contadores, de acuerdo a los tests de ANOVA / Wilcoxon-Mann-Whitney [16]. La Tabla III introduce los valores medianos de hipervolumen observados, en comparación a los obtenidos por el algoritmo estándar NSGA-II [9]. MO-SFLA es capaz de obtener valores de hipervolumen en el rango 75,39 % - 81,99 %, en comparación a los hipervolumenes de 74,95 % -

Tabla III  
COMPARATIVAS MULTIOBJETIVO: HIPERVOLUMEN

Instancia	MO-SFLA	NSGA-II
M88x3329	<b>75,39±0,04</b>	74,95±0,12
M187x814	<b>77,58±0,58</b>	76,20±0,58
M260x1781	<b>80,71±0,23</b>	77,46±0,91
M355x1263	<b>81,99±0,19</b>	80,52±0,22

Tabla IV  
COMPARATIVAS FILOGENÉTICAS: PARSIMONIA

Instancia	MO-SFLA	TNT
M88x3329	<b>33490</b>	<b>33490</b>
M187x814	<b>29847</b>	<b>29847</b>
M260x1781	<b>43529</b>	<b>43529</b>
M355x1263	<b>54823</b>	<b>54823</b>

Tabla V  
COMPARATIVAS FILOGENÉTICAS: VEROSIMILITUD

Instancia	MO-SFLA	IQ-TREE	GARLI
M88x3329	<b>-149094,84</b>	<b>-149094,84</b>	-149111,00
M187x814	<b>-133871,90</b>	-133871,96	-133876,72
M260x1781	<b>-163895,79</b>	-163899,10	-163982,64
M355x1263	<b>-231186,34</b>	-231301,11	-231859,24

80,52 % mostrados por NSGA-II. Estos resultados sugieren que MO-SFLA da lugar a la obtención de frentes de Pareto de calidad significativa en todas las instancias analizadas.

Las Tablas IV y V introducen comparativas de calidad biológica con otros métodos filogenéticos del estado del arte. En la Tabla IV, comparamos dicha calidad desde la perspectiva de parsimonia con respecto a la herramienta heurística TNT [17]. Según este criterio, el método multiobjetivo MO-SFLA es capaz de mantener, en todas las instancias analizadas, la calidad filogenética obtenida por TNT. Por su parte, la Tabla V presenta una comparativa de resultados de verosimilitud con IQ-TREE [3] y el algoritmo evolutivo GARLI [4]. Conforme a los resultados obtenidos, MO-SFLA da lugar a una mejora en verosimilitud en las instancias con mayor número de secuencias, confirmando la bondad de las soluciones generadas.

## V. CONCLUSIONES

Este trabajo ha versado sobre la evaluación de diseños paralelos y políticas de planificación para solucionar problemas de balanceo de carga en métodos metaheurísticos. Usando como caso de estudio una metaheurística multiobjetivo para reconstrucción filogenética, MO-SFLA, hemos identificado las distintas fuentes de desequilibrio de carga presentes en su diseño algorítmico. Para afrontarlos, hemos considerado el uso de distintas políticas de planificación del estándar OpenMP (estática, dinámica y guiada), así como una aproximación algorítmica alternativa basada en el empleo de contadores para equilibrar la carga de trabajo de los hilos de ejecución.

Hemos evaluado experimentalmente las técnicas planteadas en un clúster multicore compuesto por 48 núcleos de procesamiento, empleando para ello cuatro instancias del problema

basadas en datos de secuencias de proteínas. Para el diseño original, la aproximación dinámica dio lugar a un rendimiento más satisfactorio que el resto de políticas, mejorando la eficiencia media del algoritmo de 55,2 % (versión estática) a 62,7 % para 48 cores. Además, la introducción del mecanismo alternativo de balanceo basado en contadores permitió ir un paso más allá en la explotación de los recursos hardware, demostrando eficiencias hasta de 88,8 % sin afectar significativamente a la calidad de los frentes de Pareto generados.

Como trabajo futuro, pretendemos afrontar la explotación de recursos de computación heterogénea para acelerar el método propuesto, explorando alternativas dependientes e independientes el problema. Se estudiarán a su vez estrategias adaptativas para mejorar las capacidades de búsqueda en espacios de decisión difíciles de abordar, así como la evaluación del diseño en otros problemas bioinformáticos.

## REFERENCIAS

- [1] E. Alba, G. Luque, and S. Nesmachnow, "Parallel metaheuristics: recent advances and new trends," *International Transactions in Operational Research*, vol. 20, no. 1, pp. 1–48, 2013.
- [2] P. Lemey, M. Salemi, and A.-M. Vandamme, *The Phylogenetic Handbook: a Practical Approach to Phylogenetic Analysis and Hypothesis Testing*. Cambridge: Cambridge Univ. Press, 2009.
- [3] L. Nguyen, H. Schmidt, A. Haeseler, and B. Minh, "IQ-TREE: A fast and effective stochastic algorithm for estimating maximum likelihood phylogenies," *Mol. Biol. Evol.*, vol. 32, no. 1, pp. 268–274, 2015.
- [4] A. L. Bazinet, D. J. Zwickl, and M. P. Cummings, "A Gateway for Phylogenetic Analysis Powered by Grid Computing Featuring GARLI 2.0," *Systematic Biology*, vol. 63, no. 5, pp. 812–818, 2014.
- [5] W. Cancino, L. Jourdan, E.-G. Talbi, and A. C. B. Delbem, "Parallel Multi-Objective Approaches for Inferring Phylogenies," in *Proc. of EVOBIO'2010*, ser. LNCS, vol. 6023. Springer, 2010, pp. 26–37.
- [6] S. Santander-Jiménez, M. A. Vega-Rodríguez, and L. Sousa, "Multi-objective Frog-Leaping Optimization for the Study of Ancestral Relationships in Protein Data," *IEEE Trans. Evol. Comput.*, pp. 1–14 (DOI: 10.1109/TEVC.2017.2774599), 2018.
- [7] H. Matsuda, H. Yamashita, and Y. Kaneda, "Molecular Phylogenetic Analysis using both DNA and Amino Acid Sequence Data and Its Parallelization," *Genome Informatics*, vol. 5, pp. 120–129, 1994.
- [8] A. Sarkheyli, A. M. Zain, and S. Sharif, "The role of basic, modified and hybrid shuffled frog leaping algorithm on optimization problems: a review," *Soft Computing*, vol. 19, no. 7, pp. 2011–2038, 2015.
- [9] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A Fast and Elitist Multi-Objective Genetic Algorithm: NSGA-II," *IEEE Trans. Evol. Comput.*, vol. 6, no. 2, pp. 182–197, 2002.
- [10] W. Gropp, W. Lusk, and A. Skjellum, *Using MPI: Portable Parallel Programming with the Message Passing Interface. 3rd edition*. Cambridge, MA, USA: The MIT Press, 2014.
- [11] R. van der Pas, E. Stotzer, and C. Terboven, *Using OpenMP - The Next Step*. Cambridge, MA, USA: The MIT Press, 2017.
- [12] I. Morgenstern *et al.*, "A molecular phylogeny of thermophilic fungi," *Fungal Biology*, vol. 116, no. 4, pp. 489–502, 2012.
- [13] A. Kovalchuk, A. Kohler, F. Martin, and F. O. Asiegbu, "Diversity and evolution of ABC proteins in mycorrhiza-forming fungi," *BMC Evolutionary Biology*, vol. 15, no. 249, pp. 1–19, 2015.
- [14] R. Stracke *et al.*, "Genome-wide identification and characterisation of R2R3-MYB genes in sugar beet (*Beta vulgaris*)," *BMC Plant Biology*, vol. 14, no. 249, pp. 1–17, 2014.
- [15] P. J. Dias and I. Sá-Correia, "The drug:H<sup>+</sup> antiporters of family 2 (DHA2), siderophore transporters (ARN) and glutathione:h<sup>+</sup>-antiporters (GEX) have a common evolutionary origin in hemiascomycete yeasts," *BMC Genomics*, vol. 14, no. 901, pp. 1–22, 2013.
- [16] D. J. Sheskin, *Handbook of Parametric and Nonparametric Statistical Procedures. 5th edition*. NY, USA: Chapman & Hall/CRC, 2011.
- [17] P. A. Goloboff and S. A. Catalano, "TNT version 1.5, including a full implementation of phylogenetic morphometrics," *Cladistics*, vol. 32, no. 3, pp. 221–238, 2016.



# Developing Genetic Algorithms using Different MapReduce Frameworks: MPI vs. Hadoop\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Carolina Salto  
Facultad de Ingeniería  
Universidad Nacional de La Pampa  
Argentina  
minettig@ing.unlpam.edu.ar

Gabriela Minetti  
CONICET  
Argentina  
saltoc@ing.unlpam.edu.ar

Enrique Alba, Gabriel Luque  
Departamento de Lenguajes  
Universidad de Málaga  
Málaga, Spain  
{eat,gabriel}@lcc.uma.es

**Abstract**—MapReduce is a quite popular paradigm, which allows to no specialized users to use large parallel computational platforms in a transparent way. Hadoop is the most used implementation of this paradigm, and in fact, for a large amount of users the word Hadoop and MapReduce are interchangeable. But, there are other frameworks that implement this programming paradigm, such as MapReduce-MPI. Since, optimization techniques can be greatly beneficiary of this kind of data-intensive computing modeling, in this paper, we analyze the performance effect of developing genetic algorithms (GA) using different frameworks of MapReduce (MRGA). In particular, we implement MRGA using Hadoop and MR-MPI frameworks. We analyze and compare both implementations considering relevant aspects such as efficiency and scalability to solve a large dimension problem. The results show a similar efficiency level between the algorithms but Hadoop presents a better scalability.

**Index Terms**—



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

**MAEB 9: SESIÓN ESPECIAL:  
APLICACIONES EN MEDICINA  
Y BIOTECNOLOGÍA**

**Organizadores:**

JOSÉ MANUEL COLMENAR Y JOSÉ IGNACIO HIDALGO







# Strain Design as Multiobjective Network Interdiction Problem: A Preliminary Approach\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Marina Torres <i>Dept. of Computer Science and A.I.</i> <i>Universidad de Granada</i> Granada, Spain torresm@decsai.ugr.es	Shouyong Jiang <i>School of Computing</i> <i>Newcastle University</i> Newcastle, U.K. math4neu@gmail.com	David Pelta <i>Dept. of Computer Science and A.I.</i> <i>Universidad de Granada</i> Granada, Spain dpelta@decsai.ugr.es	Marcus Kaiser <i>School of Computing</i> <i>Newcastle University</i> Newcastle, U.K. marcus.kaiser@ncl.ac.uk
--	--	---	--

Natalio Krasnogor  
*School of Computing*  
*Newcastle University*  
Newcastle, U.K.  
natalio.krasnogor@ncl.ac.uk

**Abstract**—Computer-aided techniques have been widely applied to analyse the biological circuits of microorganisms and facilitate rational modification of metabolic networks for strain design in order to maximise the production of desired biochemicals for metabolic engineering. Most existing computational methods for strain design formulate the network redesign as a bilevel optimisation problem. While such methods have shown great promise for strain design, this paper employs the idea of network interdiction to fulfil the task. Strain design as a Multiobjective Network Interdiction Problem (MO-NIP) is proposed for which two objectives are optimised (biomass and bioengineering product) simultaneously in addition to the minimisation of the costs of genetic perturbations (design costs). An initial approach to solve the MO-NIP consists on a Nondominated Sorting Genetic Algorithm (NSGA-II). The shown examples demonstrate the usefulness of the proposed formulation for the MO-NIP and the feasibility of the NSGA-II as a problem solver.

**Index Terms**—strain design, network interdiction, metabolic networks, multiobjective bilevel optimisation

# Un análisis de soluciones basadas en Programación Genética para resolver problemas de regresión simbólica de datos de medidores continuos de glucosa

J. Ignacio Hidalgo, José Manuel Velasco, Juan Lanchares, Sergio Contador y Oscar Garnica  
Universidad Complutense de Madrid  
C/. Prof. José García Santesmases 9, 28040, Madrid, España  
Email: hidalgo@dacya.ucm.es

**Resumen**—Diabetes es el nombre de un grupo de enfermedades metabólicas asociadas con la incapacidad del cuerpo para regular los niveles de glucosa en sangre. Una solución ideal para la diabetes sería un páncreas artificial que fuera capaz de mantener un buen control de los niveles de azúcar en la sangre y permitir que el paciente tenga una vida normal, retrasando al mismo tiempo la aparición de complicaciones. Debido a esto, un páncreas artificial necesita realizar predicciones precisas de la evolución de la glucosa utilizando diferentes horizontes de tiempo. En este artículo analizamos diversas técnicas para la predicción de la glucosa. En concreto, comparamos la programación genética con selección estricta, una aproximación más tradicional de programación genética y *ARIMA* con ventana de 24 y 48 horas. El análisis de los resultados se realiza utilizando las métricas Clarke Error Grid y Parkes Error Grid.

## I. INTRODUCCIÓN

El páncreas es una glándula del sistema endocrino que produce insulina y glucagón. Estas dos hormonas mantienen los niveles de glucosa en sangre dentro de los rangos óptimos y regulan el metabolismo de los carbohidratos. Existe un grupo de enfermedades metabólicas asociadas con la incapacidad del cuerpo para regular el metabolismo que pueden producir niveles elevados de glucosa en sangre durante un periodo de tiempo prolongado. Estas enfermedades se llaman Diabetes [1]. En 2015, se estimó que más de 415 millones de personas en todo el mundo la padecían [2]. La Diabetes Mellitus Tipo 1 (DMT1), que suele manifestarse en edades tempranas, representa el 10 % de este número. La DMT1 es un trastorno autoinmune crónico por el que el sistema inmune ataca las células secretoras de insulina del páncreas. El resultado es que las células no asimilan el azúcar y, como consecuencia, hay un aumento en los niveles de glucosa en sangre que se conoce como hiperglucemia (niveles de glucosa en sangre superiores a 140 *mg/dl*). Si esta situación se extiende durante un largo periodo de tiempo, el

paciente puede desarrollar complicaciones graves a largo plazo, incluyendo enfermedades cardíacas, ceguera, insuficiencia renal o úlceras en los pies [3, 4].

La DMT1 solo puede tratarse con insulina sintética inyectada en el torrente sanguíneo. Sin embargo, esta no es una tarea fácil. Una dosis excesiva de insulina puede producir hipoglucemia (definida como un valor de glucosa en sangre inferior a 70 *mg/dl*). Si la hipoglucemia es muy grave (glucosa inferior a 50 *mg/dl*), puede llevar a la pérdida del conocimiento y a un coma diabético. En la Figura 1 podemos ver la evolución de los niveles de glucosa en sangre en un paciente diabético. Se observa como los niveles de glucosa se encuentran en la zona de hiperglucemia durante un periodo largo de tiempo y, los episodios de hiperglucemia grave o hipoglucemia son frecuentes.

Algunos pacientes con complicaciones graves han sido operados mediante un trasplante de páncreas, pero esta opción puede producir varios problemas nuevos. El paciente trasplantado debe tomar medicamentos inmunosupresores para evitar que su sistema inmune ataque su nuevo páncreas, y este tratamiento puede coadyuvar al desarrollo de infecciones bacterianas o virales y cáncer. Una solución ideal para la DMT1 sería un Páncreas Artificial (PA) [5] capaz de mantener el control de los niveles de azúcar en la sangre y permitir que el paciente tenga una vida normal, evitando al mismo tiempo, o al menos retrasando, la aparición de complicaciones. En la Figura 2 se muestra la estructura básica de un PA. Uno de los componentes es un sistema continuo de monitorización de la glucosa que consiste en un biosensor [6, 7] (generalmente un sensor que mide el nivel de glucosa intersticial [8]) y un transmisor inalámbrico. El otro componente es un dispositivo integrado con varias funcionalidades. Por un lado, recibe las muestras de glucosa y las almacena. Por otro lado, controla una bomba de insulina; un dispositivo que inyecta bolos de insulina en el torrente



sanguíneo. Para determinar la cantidad de insulina, el dispositivo tiene en cuenta varios factores, entre los que se encuentran el tipo y las características de la insulina. Principalmente, hay cuatro tipos de insulinas (insulina de acción rápida, de acción corta, de acción intermedia y de acción lenta) que se clasifican dependiendo del tiempo de retraso antes de que comiencen a actuar (inicio), el momento en que la insulina alcanza su máximo efecto (pico) y la demora final hasta que cesa su efecto (duración). La insulina de acción rápida, tiene un inicio entre 5-15 minutos, un pico entre 30-60 minutos y una duración entre 3-5 horas. La insulina de acción corta o regular, tiene un inicio de 30 minutos, un pico entre 2-3 horas y una duración entre 3-6 horas. La insulina de acción intermedia, tiene un inicio entre 2-4 horas, un pico entre 4-12 horas y una duración entre 12-18 horas. La insulina de acción lenta tiene un inicio entre 1-2 horas, un pico entre 6-8 horas y una duración entre 6-23 horas, dependiendo de la dosis suministrada. Debido a esto, surge la necesidad de realizar predicciones precisas de la evolución de la glucosa utilizando diferentes horizontes de tiempo.

Esta investigación está motivada por el desafío de predecir con precisión los niveles futuros de glucosa para que un sistema automático pueda decidir cuándo y cuánta insulina inyectar a fin de mantener el nivel de azúcar en la sangre en un rango saludable. Al mismo tiempo, es muy importante para un sistema de control de la glucosa en sangre, evitar las predicciones que puedan desencadenar tratamientos innecesarios o, incluso peor, tratamientos que son perjudiciales para el paciente. Aunque hay algunas aproximaciones clásicas, todavía hay mucho trabajo por hacer para las predicciones dentro de un horizonte de más de 60 minutos.

Una solución que ha demostrado ser adecuada para predecir los niveles de glucosa es la utilización de algoritmos basados en la Evolución Gramatical (EG) [9]. Sin embargo, uno de los principales obstáculos que encontraron los investigadores para entrenar a los modelos de EG es la escasez de cantidades significativas de datos. Como en muchos otros campos de la medicina, la recopilación de datos de pacientes diabéticos reales es muy compleja. Los modelos de EG entrenados con un pequeño conjunto de datos, por lo general, sufren de sobreajuste y tienen un poder de predicción limitado. Para evitar esta situación, en [10] se ha propuesto aumentar los registros de datos de glucosa con datos sintéticos con buenos resultados. También se han realizado otras comparativas entre técnicas relacionadas con la EG, como la Programación Genética (PG) con selección estricta. Sin embargo, esta última tiene un alto tiempo de ejecución.

En este artículo investigamos otras opciones; en concreto queremos comparar la programación genética con selección estricta, una aproximación más tradicio-

nal de programación genética y el método *ARIMA* con ventana de 24 y 48 horas. Además, queremos ver si los resultados tienen una interpretación correcta comparándolos utilizando las métricas de Clarke Error Grid y Parkes Error Grid.

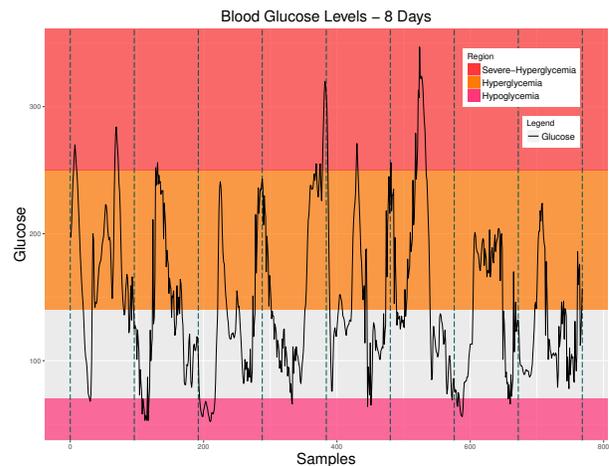


Figura 1: Valores de Glucosa Reales - 8 Días

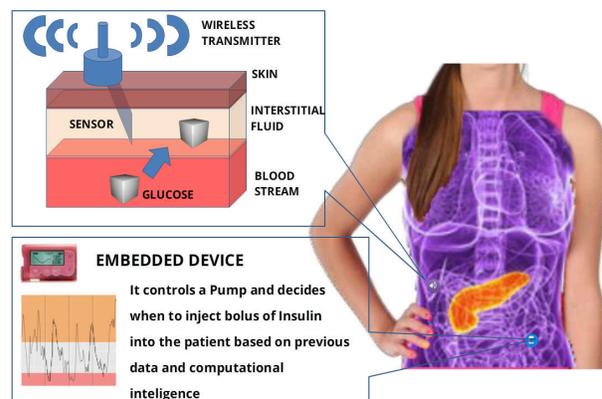


Figura 2: Páncreas Artificial

El resto del artículo está organizado de la siguiente manera. La sección II describe los antecedentes teóricos de las técnicas empleadas y explica en detalle nuestra metodología. El trabajo experimental y los resultados se muestran en la sección III.

## II. MÉTODOS

Nuestra propuesta es aplicar varias técnicas de aprendizaje con el fin de obtener modelos personalizados para la predicción del nivel de glucosa de cada paciente siguiendo un enfoque en el que los modelos se extraen de los datos. Levaremos a cabo una primera fase de entrenamiento sobre un conjunto de datos de pacientes que producirán un número de modelos que se evaluarán en una fase de prueba con datos de

los mismos pacientes. Consideramos una ventana de predicción de 2 horas. Los datos están disponibles en forma de series temporales con observaciones a intervalos de cinco minutos. Se adquieren las series de glucosa, ingestas de carbohidratos e insulinas. Hemos transformado este problema de predicción de series de tiempo en múltiples problemas de regresión independientes, donde el objetivo es encontrar modelos independientes para la predicción de la glucosa en sangre a 2 horas. De esta manera podemos aplicar cualquier técnica de regresión, incluida la regresión simbólica usando PG.

Un inconveniente de esta transformación es que los modelos no nos permiten hacer predicciones sobre ningún otro punto de la ventana de predicción. Sin embargo, esto no es un problema desde un punto de vista práctico, ya que para los pacientes diabéticos es suficiente con predecir los valores de cuatro puntos distintos en la ventana de predicción. La ventaja es que podemos utilizar los datos de los sistemas de Monitorización Continua de la Glucosa (MCG) directamente para hacer recomendaciones de insulina basadas en distintos horizontes temporales, utilizando las ecuaciones dadas por los modelos obtenidos.

Nuestro objetivo es obtener el siguiente modelo:

$$\hat{G}_{t+120} = f_{t+120}((G_{t+i}, i \in (-240 \dots 0)), (I_{t+i}, C_{t+i}, i \in (-240 \dots +120))) \quad (1)$$

donde  $t$  es el tiempo en minutos y estamos haciendo predicciones hasta 120 minutos.  $G$  es la serie temporal de valores medidos de concentración de glucosa en sangre,  $I$  es la serie temporal de insulina (bomba y bolo), y  $C$  es la cantidad de carbohidratos ingeridos según lo estimado por los pacientes. En cada instante temporal, los datos de  $t$  de hasta 4 horas antes están disponibles para la predicción. Para generar los modelos de predicción  $f_{t+120}$  usamos *ARIMA* y PG basada en árboles para la evolución de los modelos de regresión simbólica. Adicionalmente, consideramos dos predictores de referencia: *Last* y *Avg*. El primero considera la predicción como el último valor de glucosa conocido. El segundo considera la predicción como la glucosa media de los últimos valores conocidos en un intervalo de 2 horas.

### II-A. Preprocesado de datos

Los pacientes diabéticos pueden inyectarse insulina de dos formas: mediante múltiples dosis de insulina inyectada manualmente o mediante una bomba (infusor continuo) de insulina. Existen tres categorías de insulina:

- Insulina Basal
- Insulina Preprandial
- Insulina Correctora

En este artículo vamos a utilizar el modelo de absorción de Berger y Rodband [11] que describe la farmacocinética para distintos tipos de insulina.

A partir de las series temporales de glucosa, insulina y carbohidratos, definimos un conjunto de características que describimos a continuación.

Agregamos los valores de las series en intervalos de tiempo que se calculan utilizando la siguiente ecuación:

$$media(X, t, rango) = \frac{\sum_{i \in rango} (X_{i+1})}{|rango|} \quad (2)$$

El objetivo es reducir el número de características utilizadas para generar los modelos. Para cada instante de tiempo  $t$  definimos el conjunto de características  $F(t)$  que describen los valores históricos  $F_{his}$  de las series temporales  $G$ ,  $I$  y  $C$ , así como los valores futuros  $F_{fut}$  de  $I$  y  $C$ :

$$F(t) = F_{his}(G, t) \cup F_{his}(I, t) \cup F_{his}(C, t) \cup F_{fut}(I, t) \cup F_{fut}(C, t) \cup \{G, I, C\} \quad (3)$$

$$F_{his}(X, t) = \{media(X, t, [-15, 0]), media(X, t, [-30, -15]), media(X, t, [-45, -30]), media(X, t, [-60, -45]), media(X, t, [-90, -60]), media(X, t, [-120, -90])\} \quad (4)$$

$$F_{fut}(X, t) = \{media(X, t, [0, 15]), media(X, t, [15, 30]), media(X, t, [30, 45]), media(X, t, [45, 60]), media(X, t, [60, 75]), media(X, t, [75, 90]), media(X, t, [90, 105]), media(X, t, [105, 120])\} \quad (5)$$

### II-B. Programación Genética

Para cada paciente se crean cuatro modelos diferentes basados en programación genética (*PG*, *PG2*, *PG2<sub>com</sub>* y *PGOS*) para predecir el nivel de glucosa a 2 horas. Se utiliza validación cruzada de 10 iteraciones (*10-fold Cross-Validation*).

Cada modelo se generó usando el algoritmo de regresión simbólica basada en programación genética disponible en el software de código abierto HeuristicLab versión 3.3.15 [12]. Para el conjunto de terminales utilizamos las series temporales de glucosa, insulina, y carbohidratos para los modelos *PG*, *PG2* y *PGOS*; para *PG2<sub>com</sub>* utilizamos además las características precalculadas en el apartado *Preprocesado*



de datos. En todos los modelos utilizamos también constantes. Cada valor se acompaña con un peso de valor real que se inicializa aleatoriamente usando una distribución Normal  $N(\mu = 1, \sigma = 1)$ , y se muta aleatoriamente añadiendo un valor muestreado de  $N(\mu = 0, \sigma = 0.05)$ . Las constantes con valores reales son inicializadas al azar usando una distribución uniforme  $U(-20.0, 20.0)$ , y la mutación de constantes agrega un valor muestreado de  $N(\mu = 0, \sigma = 1.0)$ .

El conjunto de funciones utilizado es:  $\{+, -, *, /, \log(x), \exp(x)\}$ , donde se utilizan las variantes protegidas de las funciones división y logaritmo [13]. Los modelos en la población inicial se han generado usando *Probabistic Tree Creator* (PTC) [14] utilizando diferentes tamaños para la población, y para los árboles un límite para la profundidad máxima y un máximo número de nodos permitidos. Las mismas restricciones de profundidad y tamaño se han aplicado en las operaciones de cruce y mutación. Para el cruce, utilizamos un operador de cruce de subárbol. Para la mutación utilizamos una variedad de operadores que reemplaza un subconjunto completo del árbol con un árbol inicializado al azar, o mutan todos los nodos del árbol, o mutan solo un nodo del árbol seleccionado de forma aleatoria. El operador de mutación seleccionado al azar se ejecuta después de cada operación de cruce con una tasa de mutación diferente. Utilizamos un número máximo de generaciones y selección de aptitud proporcional de padres. No hemos sintonizado los parámetros de la PG específicamente para esta tarea de modelado, pero utilizamos configuraciones estándar robustas.

Para *PG* y *PGOS*, utilizamos un tamaño de población de 100 individuos y una profundidad máxima de árbol de 8. El número máximo de generaciones es 25 con una tasa de mutación del 25%. Para *PG2* y *PG2<sub>com</sub>*, utilizamos un tamaño de población de 300 individuos y una profundidad máxima de árbol de 11. El número máximo de generaciones es 100 con una tasa de mutación del 15%. En todos los casos utilizamos un máximo número de nodos de árbol permitidos de 100.

En el caso de *PGOS* utilizamos selección estricta de descendientes [15]. Cuando se usa selección estricta, los descendientes solo se aceptan si son mejores que ambos padres, en caso contrario son descartados. Esto tiene el efecto de que múltiples intentos repetidos de selección de padres, el cruce, la mutación opcional y la evaluación de la aptitud, son necesarios hasta que uno de los descendientes se agrega a la población de la próxima generación [16]. El umbral de presión de selección para detener el algoritmo se estableció en 100.

La función objetivo utilizada en todos los casos se calcula con el coeficiente de determinación  $R^2$

de Pearson entre los valores reales de glucosa en sangre y los valores obtenidos con el modelo [17]. Los modelos de predicción finalmente seleccionados se escalan linealmente para minimizar la suma de los errores al cuadrado entre los valores reales y los resultados del modelo.

### II-C. ARIMA

El modelo autorregresivo integrado de media móvil o *ARIMA* (Auto Regressive Integrated Moving Average) es un modelo estadístico que utiliza variaciones y regresiones de los datos, en particular series temporales, con el fin de encontrar los parámetros del modelo más adecuados para predecir los valores futuros. Se suele expresar como  $ARIMA(p, d, q)$ , donde los parámetros  $p$ ,  $d$  y  $q$ , indican el orden de las distintas componentes del modelo ( $p$  es la componente autorregresiva,  $d$  la integrada y  $q$  la media móvil). Si se considera el efecto de la estacionalidad de los datos, el modelo toma la forma  $ARIMA(p, q, d)(P, Q, D)_m$ , y está dado por la siguiente ecuación:

$$\Phi(B^m)\phi(B)(1 - B^m)^D(1 - B)^d y_t = c + \Theta(B^m)\theta(B)\varepsilon_t \quad (6)$$

donde  $\varepsilon_t$  es ruido blanco con media 0 y varianza  $\sigma^2$ ,  $B$  es el operador de retroceso, y  $\phi(z)$ ,  $\theta(z)$ ,  $\Phi(z)y\Theta(z)$ , son polinomios de orden  $p$ ,  $q$ ,  $P$  y  $Q$ , respectivamente.

Uno de los principales problemas en el uso de los modelos *ARIMA* es que el proceso de selección del orden de las componentes generalmente se considera subjetivo y difícil de aplicar. Por eso, hemos utilizado el modelo estacional *auto.arima* [18] con el software libre de análisis estadístico R versión 3.3.1 [19], que busca de forma automática las componentes del modelo seleccionando el orden apropiado.

### II-D. Clarke-Parkes Error Grid

La precisión de las predicciones se analizan con Clarke Error Grid y Parkes Error Grid. Clarke Error Grid [20] se desarrolló para calcular la precisión clínica de los sistemas de MCG en sangre para todo el rango de valores de glucosa, mediante las diferencias entre los valores medidos por el sistema de medición y los valores de referencia. Análogamente, se puede utilizar para calcular las diferencias entre los valores estimados en una predicción y los valores reales o de referencia. Los valores se representan en un gráfico con coordenadas cartesianas donde el eje X representa los valores reales y el eje Y los valores de la predicción, siendo  $Y = X$  la predicción ideal, donde el valor real coincide con el valor de la predicción. La particularidad de esta representación es que el gráfico se divide en cinco zonas dependiendo del grado de precisión

de las estimaciones de la glucosa. A continuación describimos cada una de las zonas:

- Zonas A y B: los valores en la zona A representan los valores de glucosa que se desvían de los valores de referencia menos del 20 %, o aquellos que están en el rango de hipoglucemia ( $<70$  *mg/dl*), cuando la referencia es también  $<70$  *mg/dl*. Los valores en la zona B se desvían de los valores de referencia en más del 20 %, aunque el tratamiento clínico será correcto con una alta probabilidad. Los valores que se encuentran dentro de las zonas A y B son clínicamente exactos y/o aceptables y, por lo tanto, el tratamiento será clínicamente correcto. Tratamos estas dos zonas de forma combinada en el análisis de los resultados de nuestro experimento.
- Zona C: los valores en esta zona pueden ser peligrosos en algunas situaciones. El objetivo es minimizar las predicciones incluidas en esta zona.
- Zonas D-E: los valores incluidos en estas zonas son potencialmente peligrosos, ya que la predicción está lejos de ser aceptable y el tratamiento indicado será diferente del correcto, y contrario en la zona E. De nuevo, el objetivo es minimizar las predicciones incluidas en esta zona.

Parkes Error Grid [21] se publicó en 2000 como una alternativa al uso de Clarke Error Grid. En él se redefinen las zonas basándose en las zonas de Clarke y en los límites establecidos por 100 médicos expertos en diabetes en una encuesta realizada en la conferencia *American Diabetes Association Meetings* de junio de 1994. Estas definiciones son más flexibles, y permiten incorporar el conocimiento de expertos para asignar las zonas basándose en su experiencia.

### III. RESULTADOS EXPERIMENTALES

Se realiza un estudio retrospectivo de seis pacientes con DMT1. Los datasets utilizados proceden de la Universidad de Ohio [22]. En concreto, hay dos hombres (563 y 570) y cuatro mujeres (559, 575, 588 y 591). Los datos son recolectados durante un periodo de ocho semanas mediante MCG intersticial registrada con el sistema Medtronic 530G (©Medtronic). Todos los pacientes siguen una terapia con bomba de insulina. El número de observables por paciente que tenemos se muestran en la Tabla I. Las características de cada paciente se muestran en la Tabla II. Para cada paciente se calcula la glucosa media, la desviación estándar, y los porcentajes de tiempo donde el paciente tiene niveles de glucosa por debajo de  $70$  *mg/dl*, por encima de  $250$  *mg/dl*, y en el rango  $[70, 180]$  *mg/dl*.

Tabla I: Número de observables disponibles para cada paciente.

Paciente	Observables
559	10149
563	11853
570	10580
575	11697
588	12395
591	10601

Tabla II: Características de cada paciente para los niveles de glucosa.

Paciente	Media [ <i>mg/dl</i> ]	Std [ <i>mg/dl</i> ]	$T_G < 70$ [ % ]	$T_G > 250$ [ % ]	$T_G [70, 180]$ [ % ]
559	167.22	70.50	3.95	13.11	55.54
563	145.73	49.43	2.10	2.35	74.86
570	187.22	62.37	1.80	17.16	43.75
575	139.76	58.06	8.04	4.57	70.21
588	165.09	50.60	0.94	4.96	63.47
591	156.83	57.38	3.02	7.03	64.62

Tabla III: Tiempos medios de ejecución de los modelos junto con su desviación típica.

Modelo	Tiempo [ <i>min</i> ]
<i>PG</i>	$1.54 \pm 0.14$
<i>ARIMA</i> 24h	$15.18 \pm 2.24$
<i>PG</i> <sup>2</sup> <sub>com</sub>	$19.76 \pm 1.62$
<i>PG</i> 2	$20.11 \pm 1.73$
<i>ARIMA</i> 48h	$24.40 \pm 4.42$
<i>PGOS</i>	$1453.43 \pm 140.60$

Tabla IV: Predicciones (en porcentaje) a 2h obtenidas para las distintas zonas con Clarke-Parkes Error Grid con *ARIMA* con entrenamiento de 24h y 48h.

Zona	Paciente					
	559	563	570	575	588	591
Clarke con Entrenamiento de 24h						
A	39.94	45.65	<b>58.52</b>	40.90	52.29	40.22
B	44.87	47.83	34.41	45.34	42.96	<b>49.16</b>
C	8.06	3.31	3.91	3.95	1.72	3.76
D	5.59	2.68	2.74	7.47	2.48	5.21
E	1.54	0.53	0.43	2.34	0.55	1.65
Parkes con Entrenamiento de 24h						
A	43.13	46.47	<b>61.99</b>	43.18	52.78	42.75
B	42.43	45.55	32.55	42.01	41.66	<b>46.91</b>
C	12.25	7.47	4.96	12.69	5.08	8.78
D	2.17	0.51	0.50	2.11	0.48	1.56
E	0.01	0.00	0.00	0.01	0.00	0.00
Clarke con Entrenamiento de 48h						
A	38.01	46.81	<b>61.30</b>	41.93	52.75	41.95
B	47.67	47.42	33.61	44.33	42.92	<b>48.43</b>
C	6.19	2.23	2.33	3.54	1.27	2.80
D	6.95	2.98	2.59	8.24	2.68	5.29
E	1.17	0.56	0.17	1.95	0.38	1.54
Parkes con Entrenamiento de 48h						
A	40.23	47.32	<b>63.93</b>	43.99	53.03	43.67
B	<b>45.67</b>	45.59	31.00	41.23	41.44	45.66
C	12.32	6.53	4.79	12.79	5.00	8.85
D	1.79	0.57	0.28	1.97	0.53	1.79
E	0.00	0.00	0.00	0.01	0.00	0.04



Las Tablas IV, V y VI (V y VI en ANEXO I) recogen los resultados para *ARIMA* y PG para las distintas zonas en términos de los errores Clarke y Parkes.

Podemos observar que en algunos pacientes en los que el control es muy bueno, las técnicas funcionan de una manera similar. No obstante, el mejor modelo generado que más porcentajes de valores tiene en las zonas A y B es  $PG2_{com}$ , donde el porcentaje medio en las zonas ha sido  $91.95 \pm 4.27$  [%]. El modelo generado con PG que más porcentajes de valores tiene en las zonas A y B es  $PG2_{com}$  (aparece en 8 de los 12 casos). El segundo modelo es *PGOS* (aparece en 4 de los 12 casos). Comparando *PG* con *PGOS*, el modelo mejora cuando se utiliza selección de descendencia. Comparando  $PG2$  con  $PG2_{com}$ , el modelo mejora cuando se utilizan más variables (en este caso las características) para entrenarlo. El modelo generado con *ARIMA* que más porcentajes de valores tiene en las zonas A y B es *ARIMA* con entrenamiento de 48h (aparece en 11 de los 12 casos). El modelo *ARIMA* mejora cuando se utiliza un periodo de tiempo de entrenamiento más largo.

El modelo *PGOS* no obtiene mejores resultados en la predicción a 2 horas. Por lo tanto, el tiempo empleado en la obtención del modelo (Tabla III) puede ser fundamental para la calidad de las predicciones y para la seguridad del paciente. También constatamos que la métrica Parkes es más precisa que Clarke y por consiguiente, más conveniente.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía y Competitividad de España a través de los proyectos con referencias TIN2014-54806-R y TIN2015-65460-C2.

#### REFERENCIAS

- [1] Leonid Poretsky Ed. *Principles of Diabetes Mellitus - 2017*. Springer International Publishing, 2017.
- [2] James Stephen Krinsley and Richard L. Jones. Cost analysis of intensive glycemic control in critically ill adult patients. *Chest*, 129(3):644 – 650, 2006.
- [3] American Diabetes Association. Intensive diabetes treatment and cardiovascular outcomes in type 1 diabetes: The dcct/edic study 30-year follow-up. *Diabetes Care*, 2016.
- [4] Ya-Xiong Tao (Eds.). *Glucose Homeostasis and the Pathogenesis of Diabetes Mellitus*. Progress in Molecular Biology and Translational Science 121. Academic Press, 1 edition, 2014.
- [5] Giuseppe De Nicolao, Lalo Magni, Chiara Dalla Man, and Claudio Cobelli. Modeling and control of diabetes: Towards the artificial pancreas. *{IFAC} Proceedings Volumes*, 44(1):7092 – 7101, 2011. 18th {IFAC} World Congress.
- [6] Emma P. Córcoles and Martyn G. Boutelle. *Biosensors and Invasive Monitoring in Clinical Applications*. SpringerBriefs in Applied Sciences and Technology, 2013.
- [7] Eun-Hyung Yoo and Soo-Youn Lee. Glucose biosensors: An overview of use in clinical practice. *Sensors*, 10(5):4558–4576, 2010.
- [8] Alexander Hildenbrand Hansen, Anne Katrine Duun-Henriksen, Rune Juhl, Signe Schmidt, Kirsten Nørgaard, John Bagterp Jørgensen, and Henrik Madsen. Predicting plasma glucose from interstitial glucose observations using bayesian methods. *Journal of Diabetes Science and Technology*, 8(2):321–330, 2014.
- [9] J. Ignacio Hidalgo, Esther Maqueda, José L. Risco-Martín, Alfredo Cuesta-Infante, J. Manuel Colmenar, and Javier Nobel. glucodel: A monitoring and modeling system for chronic diseases applied to diabetes. *Journal of Biomedical Informatics*, 48:183 – 192, 2014.
- [10] Jose Manuel Velasco, Oscar Garnica, Juan Lanchares, Marta Botella, and J. Ignacio Hidalgo. Combining data augmentation, edas and grammatical evolution for blood glucose forecasting. *Memetic Computing*, Jun 2018.
- [11] Markus Berger and David Rodbard. Computer simulation of plasma insulin and glucose dynamics after subcutaneous insulin injection. *Diabetes care*, 12(10):725–736, 1989.
- [12] S. Wagner and M. Affenzeller. Heuristiclab: A generic and extensible optimization environment. pages 538–541, 2005.
- [13] John R. Koza. *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press, Cambridge, MA, USA, 1992.
- [14] Sean Luke. Two fast tree-creation algorithms for genetic programming. *IEEE Trans. Evolutionary Computation*, 4:274–283, 2000.
- [15] M. Affenzeller and S. Wagner. Offspring selection: A new self-adaptive selection scheme for genetic algorithms. pages 218–221, 2005.
- [16] Michael Affenzeller, Stephan Winkler, Stefan Wagner, and Andreas Beham. Genetic algorithms and genetic programming: Modern concepts and practical applications. 01 2009.
- [17] Maarten Keijzer. Improving symbolic regression with interval arithmetic and linear scaling. pages 70–82, 2003.
- [18] Rob Hyndman and Yeasmin Khandakar. Automatic time series forecasting: The forecast package for r. *Journal of Statistical Software, Articles*, 27(3):1–22, 2008.
- [19] R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2013.
- [20] W.L. Clarke, D. Cox, L.A. Gonder Frederick, W. Carter, and S.L. Pohl. Evaluating clinical accuracy of systems for self-monitoring of blood glucose. *Diabetes Care*, 10(5):622–628, September 1987.
- [21] Pardo S Ginsberg BH. Parkes JL, Slatin SL. A new consensus error grid to evaluate the clinical significance of inaccuracies in the measurement of blood glucose. *Diabetes Care*, 23(8):1143–1148., 2000.
- [22] Cindy Marling and Razvan Bunescu. The ohio1dm dataset for blood glucose level prediction - draft.

## ANEXO I

Tabla V: Predicciones (en porcentaje) obtenidas para las distintas zonas con Clarke Error Grid para las medias y desviaciones típicas de los valores obtenidos con validación cruzada de cada paciente para los distintos modelos con horizonte de tiempo a 2 horas.

Modelo	t+120 train				t+120 test			
	A+B	C	D	E	A+B	C	D	E
<b>Paciente 559</b>								
<i>Avg</i>	84.4 ± 0.6	1.1 ± 0.2	0.1 ± 0.4	1.5 ± 0.2	81.9 ± 7.2	5.2 ± 9.2	11.1 ± 6.9	1.8 ± 2.2
<i>Last</i>	84.8 ± 0.8	7.3 ± 0.4	6.6 ± 0.3	1.3 ± 0.1	84.8 ± 6.9	7.3 ± 3.7	6.6 ± 2.5	1.3 ± 1.0
<i>PG</i>	88.1 ± 1.3	1.2 ± 0.4	10.2 ± 2.9	0.5 ± 0.2	88.3 ± 5.6	1.2 ± 0.9	10.1 ± 3.5	0.5 ± 0.5
<i>PG2</i>	89.3 ± 0.6	1.3 ± 0.1	8.8 ± 0.5	0.6 ± 0.1	89.2 ± 4.4	1.4 ± 0.8	8.8 ± 2.8	0.5 ± 0.5
<i>PG2<sub>com</sub></i>	<b>90.2 ± 0.7</b>	1.3 ± 0.2	8.1 ± 0.4	0.4 ± 0.0	<b>90.0 ± 4.2</b>	1.5 ± 0.9	8.1 ± 2.8	0.4 ± 0.4
<i>PGOS</i>	89.6 ± 0.5	1.4 ± 0.2	8.3 ± 0.4	0.6 ± 0.1	89.5 ± 4.9	1.6 ± 0.7	8.3 ± 2.7	0.6 ± 0.6
<b>Paciente 563</b>								
<i>Avg</i>	94.4 ± 0.9	0.0 ± 0.0	5.2 ± 0.3	0.3 ± 0.1	94.3 ± 7.9	0.4 ± 0.9	4.8 ± 2.6	0.5 ± 1.1
<i>Last</i>	94.4 ± 0.3	2.1 ± 0.1	2.8 ± 0.2	0.6 ± 0.1	94.4 ± 2.6	2.1 ± 1.0	2.8 ± 2.1	0.6 ± 0.6
<i>PG</i>	94.9 ± 2.5	0.2 ± 0.1	4.7 ± 0.7	0.2 ± 0.1	94.8 ± 6.0	0.2 ± 0.3	4.7 ± 2.9	0.3 ± 0.4
<i>PG2</i>	94.8 ± 2.9	0.1 ± 0.1	5.0 ± 0.8	0.1 ± 0.1	94.2 ± 7.1	0.1 ± 0.3	5.5 ± 4.0	0.1 ± 0.3
<i>PG2<sub>com</sub></i>	<b>95.5 ± 0.7</b>	0.3 ± 0.1	4.1 ± 0.3	0.2 ± 0.1	<b>95.2 ± 6.7</b>	0.3 ± 0.3	4.4 ± 2.8	0.2 ± 0.3
<i>PGOS</i>	95.4 ± 10.8	0.1 ± 0.0	4.3 ± 1.1	0.1 ± 0.1	94.8 ± 13.2	0.2 ± 0.3	4.8 ± 3.0	0.2 ± 0.4
<b>Paciente 570</b>								
<i>Avg</i>	90.9 ± 1.4	1.6 ± 0.2	6.8 ± 0.7	0.7 ± 0.1	89.7 ± 10.0	2.9 ± 4.3	7.1 ± 7.5	0.3 ± 0.7
<i>Last</i>	94.6 ± 0.9	2.2 ± 0.2	2.9 ± 0.3	0.3 ± 0.0	94.6 ± 8.3	2.2 ± 1.5	2.9 ± 2.5	0.3 ± 0.4
<i>PG</i>	95.8 ± 2.4	1.0 ± 0.2	2.9 ± 0.7	0.3 ± 0.4	95.7 ± 10.7	0.9 ± 0.9	3.1 ± 3.1	0.2 ± 0.4
<i>PG2</i>	95.8 ± 1.1	0.9 ± 0.1	3.0 ± 0.3	0.2 ± 0.0	95.9 ± 10.4	1.0 ± 0.9	3.0 ± 3.0	0.2 ± 0.4
<i>PG2<sub>com</sub></i>	<b>96.2 ± 2.3</b>	0.8 ± 0.1	2.6 ± 0.6	0.4 ± 0.4	<b>96.0 ± 10.5</b>	0.9 ± 0.7	2.8 ± 2.7	0.3 ± 0.4
<i>PGOS</i>	95.9 ± 1.0	0.9 ± 0.1	3.0 ± 0.3	0.2 ± 0.0	95.7 ± 9.9	0.9 ± 0.9	3.2 ± 3.2	0.2 ± 0.4
<b>Paciente 575</b>								
<i>Avg</i>	85.6 ± 0.6	0.1 ± 0.1	13.9 ± 0.5	0.4 ± 0.2	84.9 ± 4.2	0.8 ± 2.2	13.9 ± 4.7	0.4 ± 1.0
<i>Last</i>	86.0 ± 0.6	3.4 ± 0.3	7.5 ± 0.4	3.0 ± 0.2	86.0 ± 5.6	3.4 ± 2.3	7.5 ± 3.5	3.0 ± 2.0
<i>PG</i>	86.9 ± 0.5	0.3 ± 0.1	12.4 ± 0.5	0.3 ± 0.1	86.9 ± 7.0	0.3 ± 0.5	12.5 ± 4.1	0.3 ± 0.4
<i>PG2</i>	87.2 ± 0.7	0.3 ± 0.1	12.2 ± 0.6	0.3 ± 0.1	87.0 ± 7.0	0.3 ± 0.5	12.3 ± 4.1	0.4 ± 0.4
<i>PG2<sub>com</sub></i>	<b>87.5 ± 0.9</b>	0.3 ± 0.1	11.9 ± 0.6	0.3 ± 0.1	<b>87.5 ± 8.9</b>	0.4 ± 0.5	11.7 ± 3.8	0.4 ± 0.5
<i>PGOS</i>	<b>87.5 ± 0.7</b>	0.1 ± 0.1	12.0 ± 0.6	0.4 ± 0.1	87.3 ± 6.5	0.1 ± 0.2	12.2 ± 3.9	0.4 ± 0.3
<b>Paciente 588</b>								
<i>Avg</i>	94.4 ± 0.7	0.2 ± 0.0	5.4 ± 0.5	0.0 ± 0.0	94.4 ± 6.6	0.3 ± 0.5	5.2 ± 4.3	0.0 ± 0.1
<i>Last</i>	95.8 ± 0.6	1.4 ± 0.1	2.3 ± 0.2	0.5 ± 0.1	95.8 ± 5.9	1.4 ± 1.0	2.3 ± 1.6	0.5 ± 0.8
<i>PG</i>	95.6 ± 2.9	0.2 ± 0.1	4.0 ± 1.5	0.1 ± 0.1	95.8 ± 8.0	0.2 ± 0.3	3.9 ± 2.4	0.1 ± 0.3
<i>PG2</i>	96.1 ± 0.8	0.2 ± 0.1	3.5 ± 0.3	0.1 ± 0.0	<b>96.1 ± 7.4</b>	0.2 ± 0.3	3.5 ± 2.1	0.1 ± 0.3
<i>PG2<sub>com</sub></i>	<b>96.3 ± 0.9</b>	0.2 ± 0.1	3.4 ± 0.3	0.1 ± 0.0	<b>96.1 ± 7.6</b>	0.3 ± 0.3	3.5 ± 2.2	0.1 ± 0.2
<i>PGOS</i>	95.3 ± 3.6	0.2 ± 0.1	4.4 ± 1.9	0.1 ± 0.1	95.4 ± 8.6	0.3 ± 0.4	4.3 ± 4.0	0.0 ± 0.1
<b>Paciente 591</b>								
<i>Avg</i>	88.6 ± 1.1	0.2 ± 0.1	10.6 ± 0.7	0.6 ± 0.1	88.0 ± 6.6	0.3 ± 0.4	11.3 ± 6.1	0.5 ± 0.7
<i>Last</i>	90.4 ± 0.2	2.8 ± 0.2	5.4 ± 0.2	1.5 ± 0.1	90.4 ± 2.5	2.8 ± 2.0	5.4 ± 1.7	1.5 ± 0.9
<i>PG</i>	90.7 ± 0.7	0.4 ± 0.1	8.6 ± 0.9	0.3 ± 0.1	90.3 ± 6.1	0.4 ± 0.4	9.0 ± 3.8	0.3 ± 0.5
<i>PG2</i>	91.1 ± 0.5	0.4 ± 0.1	8.1 ± 0.3	0.4 ± 0.1	90.9 ± 5.9	0.5 ± 0.5	8.2 ± 2.9	0.4 ± 0.5
<i>PG2<sub>com</sub></i>	91.2 ± 1.3	0.5 ± 0.1	7.9 ± 1.0	0.3 ± 0.1	<b>91.4 ± 5.0</b>	0.5 ± 0.6	7.8 ± 2.7	0.4 ± 0.5
<i>PGOS</i>	<b>91.5 ± 0.6</b>	0.5 ± 0.1	7.6 ± 0.3	0.5 ± 0.1	<b>91.4 ± 5.9</b>	0.4 ± 0.4	7.7 ± 2.9	0.5 ± 0.5



Tabla VI: Predicciones (en porcentaje) obtenidas para las distintas zonas con Parkes Error Grid para las medias y desviaciones típicas de los valores obtenidos con validación cruzada de cada paciente para los distintos modelos con horizonte de tiempo a 2 horas.

Modelo	t+120 train				t+120 test			
	A+B	C	D	E	A+B	C	D	E
<b>Paciente 559</b>								
<i>Avg</i>	81.5 ± 0.7	15.8 ± 0.5	2.7 ± 0.3	0.0 ± 0.0	80.8 ± 7.3	14.9 ± 4.0	4.3 ± 5.4	0.0 ± 0.0
<i>Last</i>	84.8 ± 0.7	13.1 ± 0.4	2.1 ± 0.1	0.0 ± 0.0	84.8 ± 6.5	13.1 ± 3.3	2.1 ± 1.0	0.0 ± 0.0
<i>PG</i>	86.1 ± 1.5	12.2 ± 1.6	1.7 ± 0.2	0.0 ± 0.0	85.8 ± 6.4	12.4 ± 2.3	1.7 ± 1.7	0.0 ± 0.0
<i>PG2</i>	86.6 ± 0.7	11.7 ± 0.4	1.7 ± 0.2	0.0 ± 0.0	86.5 ± 4.8	11.8 ± 2.4	1.8 ± 1.7	0.0 ± 0.0
<i>PG2<sub>com</sub></i>	<b>87.9 ± 0.6</b>	10.8 ± 0.4	1.4 ± 0.1	0.0 ± 0.0	<b>87.8 ± 4.4</b>	10.7 ± 2.1	1.5 ± 1.4	0.0 ± 0.0
<i>PGOS</i>	86.7 ± 0.6	11.6 ± 0.4	1.7 ± 0.2	0.0 ± 0.0	86.3 ± 4.9	11.8 ± 2.3	1.8 ± 1.6	0.0 ± 0.0
<b>Paciente 563</b>								
<i>Avg</i>	90.7 ± 0.9	8.8 ± 0.6	0.5 ± 0.1	0.0 ± 0.0	89.0 ± 5.9	10.1 ± 6.6	0.9 ± 1.4	0.0 ± 0.0
<i>Last</i>	92.0 ± 0.3	7.1 ± 0.3	0.8 ± 0.1	0.0 ± 0.0	92.0 ± 2.4	7.1 ± 2.5	0.8 ± 0.7	0.0 ± 0.0
<i>PG</i>	92.4 ± 2.6	7.1 ± 0.7	0.5 ± 0.1	0.0 ± 0.0	91.8 ± 6.1	7.6 ± 4.2	0.5 ± 0.6	0.0 ± 0.0
<i>PG2</i>	92.4 ± 3.2	7.2 ± 1.1	0.4 ± 0.1	0.0 ± 0.0	92.1 ± 8.1	7.4 ± 4.4	0.5 ± 0.8	0.0 ± 0.0
<i>PG2<sub>com</sub></i>	93.6 ± 0.6	6.0 ± 0.4	0.4 ± 0.1	0.0 ± 0.0	93.2 ± 7.2	6.3 ± 3.9	0.4 ± 0.6	0.0 ± 0.0
<i>PGOS</i>	<b>93.7 ± 11.6</b>	5.9 ± 2.0	0.3 ± 0.1	0.0 ± 0.0	<b>93.3 ± 13.7</b>	6.3 ± 4.5	0.4 ± 0.5	0.0 ± 0.0
<b>Paciente 570</b>								
<i>Avg</i>	89.8 ± 1.7	8.7 ± 0.7	1.5 ± 0.2	0.0 ± 0.0	91.1 ± 15.0	8.0 ± 4.6	1.0 ± 1.1	0.0 ± 0.0
<i>Last</i>	<b>94.9 ± 0.9</b>	4.6 ± 0.3	0.5 ± 0.1	0.0 ± 0.0	<b>94.9 ± 7.8</b>	4.6 ± 2.4	0.5 ± 0.6	0.0 ± 0.0
<i>PG</i>	93.9 ± 2.3	5.4 ± 0.6	0.6 ± 0.4	0.0 ± 0.0	94.1 ± 10.3	5.4 ± 3.4	0.5 ± 0.6	0.0 ± 0.0
<i>PG2</i>	94.3 ± 1.1	5.3 ± 0.4	0.5 ± 0.1	0.0 ± 0.0	94.0 ± 9.4	5.5 ± 3.8	0.5 ± 0.6	0.0 ± 0.0
<i>PG2<sub>com</sub></i>	94.6 ± 1.6	4.9 ± 0.7	0.6 ± 0.3	0.0 ± 0.0	94.4 ± 9.1	5.1 ± 3.9	0.5 ± 0.6	0.0 ± 0.0
<i>PGOS</i>	94.3 ± 1.1	5.1 ± 0.4	0.5 ± 0.1	0.0 ± 0.0	93.9 ± 9.0	5.6 ± 3.8	0.5 ± 0.6	0.0 ± 0.0
<b>Paciente 575</b>								
<i>Avg</i>	83.9 ± 0.6	13.4 ± 0.5	2.7 ± 0.2	0.0 ± 0.0	82.5 ± 5.8	15.1 ± 3.4	2.4 ± 1.3	0.0 ± 0.0
<i>Last</i>	83.2 ± 0.5	14.4 ± 0.7	2.3 ± 0.1	0.0 ± 0.0	83.2 ± 4.7	14.4 ± 6.1	2.3 ± 1.1	0.0 ± 0.0
<i>PG</i>	84.6 ± 0.4	13.4 ± 0.6	1.9 ± 0.2	0.0 ± 0.0	84.4 ± 6.1	13.7 ± 6.0	1.9 ± 0.8	0.0 ± 0.0
<i>PG2</i>	84.7 ± 0.6	13.5 ± 0.6	1.8 ± 0.2	0.0 ± 0.0	84.5 ± 6.2	13.6 ± 6.2	1.9 ± 0.9	0.0 ± 0.0
<i>PG2<sub>com</sub></i>	<b>86.7 ± 1.2</b>	11.9 ± 0.4	1.4 ± 0.1	0.0 ± 0.0	<b>86.4 ± 7.7</b>	12.2 ± 6.0	1.5 ± 1.0	0.0 ± 0.0
<i>PGOS</i>	84.7 ± 0.6	13.5 ± 0.7	1.8 ± 0.1	0.0 ± 0.0	84.4 ± 5.9	13.8 ± 6.1	1.8 ± 0.9	0.0 ± 0.0
<b>Paciente 588</b>								
<i>Avg</i>	94.6 ± 0.8	5.1 ± 0.4	0.3 ± 0.1	0.0 ± 0.0	95.0 ± 7.0	4.7 ± 3.3	0.4 ± 0.6	0.0 ± 0.0
<i>Last</i>	94.3 ± 0.7	5.1 ± 0.3	0.6 ± 0.1	0.0 ± 0.0	94.3 ± 6.9	5.1 ± 2.6	0.6 ± 0.8	0.0 ± 0.0
<i>PG</i>	94.9 ± 3.8	4.7 ± 0.5	0.4 ± 0.1	0.0 ± 0.0	94.7 ± 7.4	4.8 ± 3.2	0.4 ± 0.7	0.0 ± 0.0
<i>PG2</i>	95.1 ± 0.8	4.5 ± 0.3	0.4 ± 0.1	0.0 ± 0.0	94.9 ± 7.0	4.6 ± 3.2	0.5 ± 0.8	0.0 ± 0.0
<i>PG2<sub>com</sub></i>	<b>95.3 ± 0.8</b>	4.4 ± 0.3	0.4 ± 0.1	0.0 ± 0.0	<b>95.0 ± 7.1</b>	4.6 ± 3.4	0.4 ± 0.7	0.0 ± 0.0
<i>PGOS</i>	94.9 ± 5.0	4.5 ± 0.4	0.5 ± 0.1	0.0 ± 0.0	94.3 ± 8.0	5.2 ± 3.9	0.5 ± 0.9	0.0 ± 0.0
<b>Paciente 591</b>								
<i>Avg</i>	87.0 ± 1.0	11.2 ± 0.3	1.8 ± 0.2	0.0 ± 0.0	87.3 ± 6.4	10.8 ± 3.8	1.8 ± 2.2	0.0 ± 0.0
<i>Last</i>	89.8 ± 0.3	8.6 ± 0.3	1.6 ± 0.1	0.0 ± 0.0	89.8 ± 2.8	8.6 ± 2.9	1.6 ± 1.0	0.0 ± 0.0
<i>PG</i>	90.2 ± 1.0	8.2 ± 0.6	1.6 ± 0.2	0.0 ± 0.0	90.2 ± 5.8	8.2 ± 3.4	1.7 ± 1.8	0.0 ± 0.0
<i>PG2</i>	90.6 ± 0.5	7.7 ± 0.3	1.6 ± 0.2	0.0 ± 0.0	90.4 ± 6.0	8.0 ± 3.0	1.7 ± 1.8	0.0 ± 0.0
<i>PG2<sub>com</sub></i>	90.2 ± 1.6	8.4 ± 0.7	1.4 ± 0.2	0.0 ± 0.0	89.9 ± 5.2	8.6 ± 3.5	1.5 ± 1.5	0.0 ± 0.0
<i>PGOS</i>	<b>90.8 ± 0.6</b>	7.7 ± 0.3	1.5 ± 0.2	0.0 ± 0.0	<b>90.5 ± 6.4</b>	7.7 ± 2.7	1.7 ± 1.7	0.0 ± 0.0

# Registrado de Imagen Médica mediante Algoritmos de Optimización basados en Arrecifes de Coral

E. Bermejo\*, M. Chica†, S. Damas\*, S. Salcedo-Sanz‡ and O. Cordon\*§

\* Instituto Andaluz en Data Science and Computational Intelligence (DaSCI), Universidad de Granada, Granada 18071.

Email: ebermejo@decsai.ugr.es, sdamas@ugr.es

† School of Electrical Engineering and Computing, The University of Newcastle, Callaghan 2380, Australia.

Email: manuel.chicaserrano@newcastle.edu.au

‡ Departamento de Teoría de la Señal y Comunicaciones, Universidad de Alcalá, Alcalá de Henares 28805.

Email: sancho.salcedo@uah.es

§ Centro de Investigación en Tecnologías de la Información, Universidad de Granada, Granada 18071

Email: oordon@decsai.ugr.es

**Resumen**—El Registrado de Imágenes (RI) conlleva la transformación de un conjunto de imágenes en un sistema de coordenadas común. Generalmente, la búsqueda de la correspondencia óptima entre imágenes es considerada un problema de optimización. Los enfoques basados en metaheurísticas permiten resolver el problema de RI superando las numerosas limitaciones de los métodos tradicionales. En esta contribución consideraremos un reciente método bio-inspirado: Optimización por Arrecifes de Coral (CRO). Este novedoso algoritmo simula los fenómenos naturales que subyacen a un arrecife de coral. Adaptaremos el algoritmo siguiendo dos enfoques de registrado diferentes: basado en características y basado en intensidades. Además, diseñaremos un exhaustivo estudio experimental considerando un problema de RI médica con resonancias magnéticas cerebrales. Los resultados muestran cómo CRO supera al estado del arte en RI tanto en robustez como en precisión y eficiencia siguiendo ambos enfoques.

## I. INTRODUCCIÓN

En el ámbito de la imagen médica existe un gran interés en relacionar la información procedente de diferentes imágenes. Esta tarea es relevante en un gran número de aplicaciones: diagnóstico, monitorización y seguimiento de enfermedades o cirugía asistida, entre otras. Generalmente, estas aplicaciones requieren la integración de información visual adquirida por diferentes dispositivos o condiciones. Así, el Registrado de Imágenes (RI) [1] es considerado como una tarea de preprocesamiento esencial en imagen médica, ya que permite alinear múltiples imágenes con contenido común.

Generalmente, los métodos de RI consideran una transformación espacial para alinear imágenes solapando regiones coincidentes. El problema se trata como un proceso de optimización iterativo que explora el espacio de transformaciones posibles. La calidad de una solución se define así por el grado de semejanza entre imágenes tras la transformación, que se mide mediante una métrica de similitud [2].

El proceso de RI permite emplear una imagen completa (enfoque de intensidades) o basarse en partes distintivas de la imagen (características). Los enfoques de características [1] agilizan el proceso de optimización reduciendo la complejidad del problema, al usar una porción de las imágenes. Sin embargo, estos métodos dependen en gran medida del proceso

de extracción de características, una etapa propensa a errores si la información extraída no es suficientemente representativa. Por otro lado, los enfoques de intensidades permiten procesar un volumen de datos mayor, a costa de incrementar los requisitos computacionales [2]. Así, la alineación se guía por la distribución de intensidades (niveles de gris) de la imagen, aumentando la precisión de estos métodos, pero también su sensibilidad al ruido o a las condiciones de iluminación.

Métodos tradicionales, como Iterative Closest Point (ICP) [3] tienden a quedar atrapados en mínimos locales debido a factores como el ruido, la discretización o la desalineación entre imágenes. Mientras tanto, aquellos basados en algoritmos evolutivos u otras metaheurísticas (MHs) permiten superar estas desventajas y ofrecen un buen rendimiento que los hace idóneos para problemas de RI médica.

Hasta la fecha se han propuesto numerosos estudios comparativos para analizar el rendimiento de diferentes MHs en problemas de RI empleando modelos craneales e imágenes médicas en 3D [4], [5]. En ambos estudios se incluyen métodos de RI relevantes: ICP, una versión adaptativa de descenso de gradiente estocástico (ASGD) y algoritmos genéticos (GAs). Entre las diversas MHs destaca una versión memética del método scatter search (SS) propuesta en [4] y extendida en [6], obteniendo resultados excelentes y consolidando su dominancia en el estado del arte sobre métodos convencionales.

Recientemente se ha propuesto una MH bio-inspirada denominada *Coral Reefs Optimization* (CRO) [7]. CRO es un algoritmo evolutivo basado en la simulación de los fenómenos naturales que ocurren durante la formación de un arrecife de coral. A lo largo de su vida, los corales atraviesan diversas fases, como la reproducción, el asentamiento de larvas o la lucha por un espacio en el arrecife donde sobrevivir. CRO emula dichos procesos favoreciendo un equilibrio entre diversidad y especificidad, ingredientes idóneos para abordar problemas complejos de optimización.

Dados los buenos resultados de CRO en diferentes problemáticas reales, consideramos que su diseño puede comportarse adecuadamente en problemas de RI complejos. Así, en este trabajo diseñamos un nuevo método de RI basado en



CRO donde tanto la función objetivo como la codificación han sido adaptados a un problema concreto de RI médica.

Para validar nuestra propuesta, hemos desarrollado un exhaustivo estudio experimental comparando CRO contra algunos métodos evolutivos del estado del arte en RI, considerando tanto enfoques de intensidades como de características. Esta comparativa es una extensión de nuestra propuesta donde adaptamos CRO al enfoque de intensidades [8]. Se han utilizado pares de imágenes monomodales extraídas de Brainweb, dataset disponible gracias a McGill University [9].

## II. REGISTRADO DE IMÁGENES: PLANTEAMIENTO

Generalmente, en los problemas de RI médica se parte de dos imágenes, una de referencia o modelo ( $I_M$ ), y una imagen móvil o escena ( $I_E$ ) que se alinea con la geometría del modelo. El objetivo del proceso de registrado es encontrar una transformación geométrica  $T$  que haga el modelo  $I_M$  y la escena transformada  $T(I_E)$  sean lo más similares posible. El grado de semejanza entre imágenes se mide considerando una métrica de similitud. Así, el RI se formula como un problema de maximización en el espacio de transformaciones:

$$\operatorname{argmax}_{T \in \text{Transformaciones}} \text{Similitud}(I_M, T(I_E)).$$

El proceso iterativo de un método de RI consta de tres componentes principales: el modelo de transformación, la métrica de similitud, y el optimizador. En primer lugar, el optimizador estima una transformación geométrica para alinear las imágenes, que viene determinada por el *modelo de transformación*. La Figura 1 ilustra el efecto de aplicar diferentes tipos de transformación a una resonancia magnética (IRM) cerebral. La elección del modelo adecuado depende tanto de la aplicación concreta como de la naturaleza de las imágenes. En ciertos contextos un modelo más simple (transformación de traslación) puede ser adecuado, mientras que otras aplicaciones que suponen una estimación de movimiento requieren modelos deformables. De cualquier forma, el tipo de transformación debe ser seleccionado cuidadosamente, ya que de esta elección dependen tanto los requisitos computacionales en base al número de parámetros a estimar, como los efectos geométricos resultantes de la transformación.

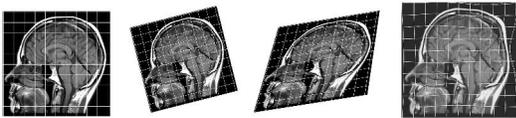


Figura 1: Aplicación de diferentes modelos de transformación: similitud, finidad y b-spline, sobre una escena inicial.

Tras ello, la *métrica de similitud* mide la calidad de la alineación entre la escena transformada y el modelo. La elección de esta métrica es un paso crucial en el diseño de cualquier método de RI y depende del enfoque considerado. Enfoques de características suelen considerar el error cuadrático medio (ECM) como métrica para medir la distancia entre

características correspondientes. Enfoques de intensidades se basan en la relación entre distribuciones de intensidad para evaluar la similitud. Existen multitud de métricas disponibles (correlación normalizada (CN) o información mutua (IM), entre otras) y su idoneidad viene determinada por el proceso de adquisición y la relación entre imágenes.

Por último, el *optimizador* refina la solución hasta alcanzar un criterio de parada (cuando se encuentra una solución adecuada o se realiza un número determinado de iteraciones). Así, la optimización de la transformación espacial supone un proceso de búsqueda iterativo sobre el espacio de transformaciones geométricas. De acuerdo con las características del espacio de búsqueda, podemos encontrar dos estrategias diferentes. El registrado puede considerarse como un problema de optimización continua cuando la búsqueda se realiza en base a los parámetros de la transformación. Alternativamente, la búsqueda se puede realizar en el espacio de correspondencias entre pares de características (enfoque de características) o entre áreas de la imagen (enfoque de intensidades).

### A. Algoritmos evolutivos relevantes en RI médica

#### RI basado en intensidades

*r-GA\**, Valsecchi et al.: r-GA\* se basa en un *algoritmo genético* [10]. El optimizador está diseñado en codificación real donde una solución almacena los parámetros de la transformación en un vector. Los operadores genéticos también son reales: cruce por mezcla alfa (BLX- $\alpha$ ) [11] y mutación aleatoria. r-GA\* es capaz de adaptar diferentes métricas de similitud y distintos modelos de transformación. Además, integra el uso de múltiples resoluciones en combinación con un mecanismo de reinicio y adaptación al espacio de búsqueda. Estos mecanismos permiten agilizar el proceso de optimización y mitigar una convergencia prematura.

*SS\**, Valsecchi et al.: SS\* [6] es una variante del diseño original de *scatter search* o búsqueda dispersa, donde el conjunto de referencia se divide en dos para contener las soluciones más diversas y las de mayor calidad. El algoritmo han sido diseñados específicamente para RI [4]. Así, SS\* considera el uso de memoria basada en frecuencia para el método de diversificación, la combinación de soluciones se basa en el cruce BLX- $\alpha$ , y el método de mejora en el operador PMX- $\alpha$  [12]. El método de actualización clasifica las soluciones según su calidad o diversidad. Finalmente, el método de control de duplicación previene la aparición de copias idénticas de una solución en la población.

#### RI basado en características

*HE-GA*, He y Narayana: Propuesto en [13], considera un diseño genético con codificación real combinado con *dividing rectangle*, un método de optimización global basado en ramificación y poda. El genético sigue un modelo generacional elitista con cruce aritmético y mutación uniforme, aplicado para estimar una solución preliminar. Esta solución es posteriormente refinada por búsqueda local. Incorpora un mecanismo de reinicio para evitar una convergencia prematura.

SS, Santamaría *et al.*: Este método basado en SS fue originalmente diseñado para problemas de RI de rango [4]. Los autores adoptan una métrica de similitud basada en el error cuadrático mediano (ECMed), robusta a imágenes con bajo solapamiento, integran una estructura de datos para acelerar el cálculo de la función objetivo, y una búsqueda local basada en cruce (XLS) como método de mejora. SS también incluye un mecanismo de reinicio para evitar mínimos locales.

### III. CORAL REEFS OPTIMIZATION ALGORITHM

CRO [7], [14] es un algoritmo evolutivo basado en los procesos naturales de un arrecife de coral. Denominamos  $\mathcal{R}$  a un arrecife representado por una cuadrícula  $R_1 \times R_2$ , donde cada posición  $(i, j)$  permite albergar a un coral,  $C_{i,j}$ , que representa una solución al problema de optimización considerado. El algoritmo inicializa varios corales en posiciones aleatorias de  $\mathcal{R}$ , dejando huecos libres para el asentamiento de futuras generaciones de corales. La ratio entre posiciones libres/ocupadas viene dado por un parámetro  $\rho_0$ , donde  $0 < \rho_0 < 1$ .

Existen diferentes mecanismos reproductivos en un arrecife de coral. En CRO se recrean aplicando diferentes operadores de forma secuencial durante la segunda fase del algoritmo:

#### 1. Reproducción sexual externa (*Broadcast Spawning*).

En cada iteración  $k$  del algoritmo se aplica:

- 1.a. Selección uniforme de una fracción aleatoria  $F_b$  de corales (denominados *broadcast spawners*) con respecto al total de corales existentes en el arrecife.
- 1.b. Formación de larvas. Se eligen dos broadcast spawners y se aplica un operador de cruce. Una vez seleccionados, éstos no vuelven a atravesar otra etapa reproductiva durante la iteración  $k$ . La selección puede ser uniforme, aleatoria o proporcional al fitness (selección por ruleta).

#### 2. Reproducción sexual interna (*Brooding*).

La reproducción de los corales hermafroditas se modela como una mutación sobre una fracción de los corales restantes  $1 - F_b$ . En estos casos, un porcentaje  $P_i$  del coral muta.

#### 3. Asentamiento de larvas.

Las nuevas larvas generadas seleccionan una posición aleatoria del arrecife para formarse, siempre que la posición  $(i, j)$  esté libre. En caso de que esté ocupada, la nueva larva se asentará si su valor de fitness mejora a la del coral existente. El máximo número de intentos para ocupar una posición en cada iteración  $k$  está limitado por el parámetro  $\eta = 3$ .

#### 4. Reproducción asexual.

Los corales pueden fragmentarse y reasentarse en el arrecife (*budding*). CRO modela este mecanismo ordenando los corales por su nivel de vida (fitness  $f(C_{i,j})$ ). Una pequeña fracción ( $F_a$ ) de los corales se duplica, muta con probabilidad  $P_a$ , e intenta asentarse en el arrecife como en el paso 3.

#### 5. Depredación.

Tras cada iteración  $k$ , se simula la muerte de un pequeño número de corales, liberando espacio en el arrecife para la siguiente generación. La depredación se aplica con una probabilidad muy pequeña ( $P_d$ ) a una fracción  $F_d$  de corales con peor vida.

## IV. DISEÑO EXPERIMENTAL

Diseñamos un estudio experimental considerando los algoritmos descritos en la Sección A ya que mejoran el comportamiento de alternativas clásicas [5], [6], [8], [10]. Así, pretendemos realizar un análisis exhaustivo del comportamiento de nuestra propuesta en comparación con los métodos evolutivos más relevantes en un problema de RI médica.

### A. Escenarios y dataset de imágenes

Las imágenes mono-modales utilizadas en esta experimentación han sido obtenidas de un repositorio público muy conocido, BrainWeb (McGill University [9]). Este dataset se compone de imágenes cerebrales simuladas a partir de IRMs sintéticas. Con el objetivo de considerar diferentes niveles de complejidad, las imágenes contienen ruido (hasta un 5%) y múltiples lesiones (esclerosis). Las imágenes tienen un tamaño común de  $60 \times 181 \times 217$  voxels.

A partir de la curvatura cerebral de cada imagen extraemos un conjunto de puntos mediante un detector de líneas de cresta [15]. En enfoques de características, los valores heurísticos de curvatura se emplean para guiar al optimizador durante la estimación de la transformación de registrado.

Para generar diferentes escenarios, cada imagen ha sido transformada usando una de las cuatro transformaciones de similitud (aplicando rotación, traslación y escalado uniforme) de la Tabla I. En total, el estudio consta de 16 instancias de RI creadas a partir de pares de imágenes con diferentes transformaciones. Los escenarios son:  $I_1$  vs.  $T_i(I_2)$ ,  $I_1$  vs.  $T_i(I_3)$ ,  $I_1$  vs.  $T_i(I_4)$ , e  $I_2$  vs.  $T_i(I_4)$ , para  $i = 1, 2, 3, 4$ .

Tabla I: Parámetros de la transformación: ángulo de rotación ( $\lambda$ ), eje de rotación ( $a_x, a_y, a_z$ ), vector de traslación ( $t_x, t_y, t_z$ ), y factor de escalado uniforme  $s$ .

	$\lambda$	$a_x$	$a_y$	$a_z$	$t_x$	$t_y$	$t_z$	$s$
$T_1$	115	-0.863	0.259	0.431	-26	15.5	-4.6	1
$T_2$	168	0.676	-0.290	0.676	6	5.5	-4.6	0.8
$T_3$	235	-0.303	-0.808	0.505	16	-5.5	-4.6	1
$T_4$	276.9	-0.872	0.436	-0.218	-12	5.5	-24.6	1.2

### B. Diseño Experimental y Configuración

Los métodos de la comparativa difieren en el proceso de optimización: los enfoques de características se guían por los puntos de curvatura y las métricas ECM o ECMed, mientras que los enfoques de intensidades se guían por los valores de intensidad y métricas como CN o IM. Los resultados de diferentes métricas no son comparables, por lo que es necesario definir un marco comparativo para evaluar objetivamente los resultados de la alineación. Así, consideramos una medida común para evaluar la calidad de todas las soluciones. Una vez el algoritmo alcanza una solución, se calcula el ECM entre las características anatómicas (líneas de cresta) de la escena transformada y las del modelo. Este valor será usado como comparativa de la calidad final para todos los métodos.

La transformación de similitud que relaciona las imágenes considera un rango de  $[-30, 30]$  para los parámetros de la



Tabla II: Parameter configuration for considered IR methods.

r-GA*		SS*		CRO*		HE-GA		SS		CRO	
Individuos	100	Tamaño población	12	Tamaño arrecife	80	Individuos	60	Tamaño población	30	Tamaño arrecife	70
Generaciones	75	Generaciones	18	Generaciones	65	Reinicios	5	Reinicios	5	Reinicios	15
Reinicios	5	Reinicios	3	Reinicios	8	Factor $\alpha$	0.3	XLS iter.	100	XLS iter.	100
Torneo	3	PMX iter.	12	PMX iter.	15	Prob. cruce	0.7	Factor $\alpha$	0.3	$\rho_0$	0.6
Factor $\alpha$	0.3	Factor $\alpha$	0.3	$\rho_0$	0.6	Prob. mutación	0.2	Conjunto Referencia	8	$F_{broad}$	0.9
Prob. cruce	0.5	conjunto referencia	4	$F_{broad}$	0.8					$P_d$	0.05
Prob. mutación	0.1			$P_d$	0.15					$k$	3

traslación y  $[0,75,1,25]$  para el factor de escalado. No se aplica restricción en el ángulo de rotación ( $[0,360]$ ), ni en sus ejes ( $[-1,1]$ ). De esta forma, la transformación se codifica mediante un vector real de siete parámetros en el enfoque de intensidades: versor de rotación  $(\theta_x, \theta_y, \theta_z)$ , vector de traslación  $(t_x, t_y, t_z)$  y escalado uniforme  $s$ . En el enfoque de características, la rotación se codifica con cuatro parámetros: tres para el eje de rotación  $(r_x, r_y, r_z)$  y uno para el ángulo  $\theta_r$ , resultando en una codificación de ocho parámetros.

Para evaluar CRO en comparación con el estado del arte en RI (Sección A), diseñamos un estudio experimental considerando métodos representativos de ambos enfoques (intensidades y características). Así, comparamos seis métodos diferentes: i) *Enfoque de intensidades*: r-GA\*, SS\* y CRO\*. ii) *Enfoque de características*: HE-GA, SS y CRO.

Dadas las diferencias en términos de requisitos computacionales, la configuración de parámetros óptima para cada algoritmo varía según el enfoque considerado (ver Tabla II). Estos parámetros han sido ajustados manualmente con un par de imágenes no incluido en la experimentación para evitar sesgos. Se han seguido las directrices marcadas por los autores en estudios previos [5], [7]. A continuación detallamos las características distintivas de los métodos:

*Diseño de métodos basados en intensidades*:: La implementación se ha realizado en Elastix [16], una herramienta open-source específicamente diseñada para RI médica de intensidades. El método basado en CRO se ha propuesto en [8] con resultados prometedores. El optimizador se guía por la métrica normalizada de información mutua (IMN):

$$NMI(I_A, I_B) = \frac{\sum_{a \in I_A} \sum_{b \in I_B} p_{AB}(a, b) \log(p_A(a)p_B(b))}{\sum_{a \in I_A} \sum_{b \in I_B} p_{AB}(a, b) \log p_{AB}(a, b)},$$

donde  $p_{AB}$  es la probabilidad conjunta y  $p_A, p_B$  son las probabilidades marginales discretas de las intensidades de las imágenes.

Además, el diseño de los enfoques de intensidades integra dos componentes: i) **Multi-resolución** para reducir el coste computacional del proceso, mediante una reducción de la resolución y un suavizado gaussiano para crear dos representaciones (pirámides) de la imagen. En la primera resolución, el optimizador considera una pirámide de baja resolución para aproximar la transformación. La segunda resolución consiste en una etapa de refinado para mejorar la calidad de la alineación. ii) **Mecanismo de reinicio** para asegurar que el algoritmo es capaz de recuperarse de un posible estancamiento y encuentre una buena solución. En la primera resolución, se

aplica un reinicio del algoritmo un número determinado de veces. La mejor solución de esta etapa pasa a la etapa de refinado. Dado el gran volumen de datos, el tiempo de ejecución total de cada algoritmo se ha limitado a 180 segundos.

*Diseño de métodos basados en características*:: Implementados en C++ y compilados con la herramienta GNU/g++, siguen una estructura similar al enfoque de intensidades. Puesto que ECM ha sido elegido para la comparativa final, consideramos una métrica de optimización diferente para evitar favorecer este diseño. Así, consideramos una variante de ECMed específicamente diseñada para IR:

$$F(f, I_E, I_M) = w_1 \cdot (1 / (1 + \sum_{i=1}^N ||(sR\vec{p}_i + \vec{t}_i) - \vec{p}_j^i||)) + w_2 \cdot (1 / (1 + |p_c^e - p^m|)),$$

donde  $f$  es la solución que codifica los parámetros de la transformación;  $p_i$  es un punto 3D de la escena y  $p_j$  su correspondencia más cercana en el modelo utilizando una estructura de indexación (*grid closest point*);  $w_1$  y  $w_2$  ( $w_1 + w_2 = 1$ ) son pesos para balancear los términos de la función;  $p_c^e$  es el radio de la esfera que engloba la escena transformada y  $p^m$  el radio de la esfera sobre el modelo. Nótese que el primer término de  $F$  corresponde con la función ECMed entre puntos vecinos.

Como componentes específicos de este enfoque, se aplica el reinicio de la población cuando el optimizador detecta estancamiento, por ejemplo, tras 15 iteraciones sin mejora. El conjunto de características (líneas de cresta) es bastante reducido, por lo que no se requiere una estrategia multi-resolución y el tiempo de parada se limita a 20 segundos.

### C. Análisis de Resultados

En la Tabla III se recogen los resultados de la alineación entre imágenes: el error entre pares de características (ECM) y el ranking parcial de cada método en los 16 escenarios. Nótese que el mínimo valor posible de ECM se explica por los niveles de ruido y la presencia de lesiones en la comparación entre imágenes. El valor óptimo de ECM se ha resaltado entre paréntesis en la Tabla III. Además, se ha realizado un análisis estadístico sobre los valores medios para buscar diferencias significativas entre el algoritmo con mejor ranking y el resto. Los resultados del ranking, test de Bonferroni-Dunn y test de Holm se recogen en la Tabla IV.

En general, los métodos basados en características mejoran a sus homólogos de intensidades en la mayoría instancias. El diseño del optimizador hace que este tipo de métodos pueda alcanzar una mayor precisión en menor tiempo. Así,

Tabla III: Mínimo (m), media ( $\mu$ ) y desviación estándar (sd) para los valores de ECM (mm) y ranking medio (R) para cada instancia de RI. Las columnas subrayadas corresponden con los métodos basados en intensidades.

Algorithm	$I_1$ vs $T_1(I_2)$ [31]				$I_1$ vs $T_2(I_2)$ [31]				$I_1$ vs $T_3(I_2)$ [31]				$I_1$ vs $T_4(I_2)$ [31]			
	m	$\mu$	sd	R												
r-GA*	37.32	134	>99	6	39.60	86.43	44	5	43.29	5506	>99	6	32.19	84.36	91	6
HE-GA	42.69	101	47	5	<b>31.85</b>	44.27	17	4	<b>31.96</b>	42.19	9	4	32.88	59.23	28	5
SS*	36.01	38.14	5.9	4	36.53	38.96	2.9	3	36.78	1755	>99	5	32.65	32.96	0.7	4
SS	32.06	32.84	2.2	2	32.11	119	>99	6	32.17	41.08	47	2	<b>32.00</b>	32.25	0.1	2
CRO*	36.35	36.79	0.3	3	36.26	36.78	0.3	2	40.72	41.41	0.5	3	32.67	32.79	0.1	3
CRO	32.11	<b>32.25</b>	0.1	1	32.10	<b>33.96</b>	5.3	1	32.14	<b>32.27</b>	0.1	1	32.14	<b>32.24</b>	0.0	1

Algorithm	$I_1$ vs $T_1(I_3)$ [42]				$I_1$ vs $T_2(I_3)$ [42]				$I_1$ vs $T_3(I_3)$ [42]				$I_1$ vs $T_4(I_3)$ [42]			
	m	$\mu$	sd	R												
r-GA*	50.61	142	>99	6	45.61	97.75	81	6	66.00	8470	>99	6	42.93	86.11	53	5
HE-GA	61.65	122	48	5	<b>42.91</b>	61.01	24	4	56.52	74.44	18	5	58.74	114	42	6
SS*	50.20	61.34	50	4	43.65	46.36	3.9	3	55.22	57.85	3.2	4	44.68	45.18	0.3	4
SS	<b>42.96</b>	58.69	59	3	43.08	83.82	>99	5	43.06	50.95	41	2	42.95	43.44	0.6	2
CRO*	51.23	51.77	0.3	2	43.54	43.73	0.1	1	55.78	56.53	0.4	3	44.61	45.17	0.3	3
CRO	43.01	<b>43.29</b>	0.2	1	42.94	<b>44.06</b>	2.9	2	<b>42.97</b>	<b>43.45</b>	0.2	1	<b>42.87</b>	<b>43.39</b>	0.3	1

Algorithm	$I_1$ vs $T_1(I_4)$ [46]				$I_1$ vs $T_2(I_4)$ [46]				$I_1$ vs $T_3(I_4)$ [46]				$I_1$ vs $T_4(I_4)$ [46]			
	m	$\mu$	sd	R												
r-GA*	51.06	151	>99	6	58.92	124	98	4	60.76	9428.7	>99	6	<b>46.44</b>	82.74	45	5
HE-GA	60.07	119	51	5	84.3	1011	>99	6	51.18	78.92	25	5	51.35	92.56	30	6
SS*	52.53	53.67	1.3	3	46.48	48.12	1.5	2	54.32	60.10	5.2	3	46.65	47.58	0.5	3
SS	46.79	61.77	77	4	46.52	154	>99	5	46.87	64.26	68	4	46.67	<b>47.33</b>	0.5	1
CRO*	52.78	53.24	0.3	2	<b>46.02</b>	<b>46.37</b>	0.1	1	57.46	58.02	0.3	2	47.03	47.70	0.3	4
CRO	<b>46.66</b>	<b>48.85</b>	6.0	1	46.77	48.80	3.4	3	<b>46.80</b>	<b>47.57</b>	0.6	1	46.64	47.37	0.6	2

Algorithm	$I_2$ vs $T_1(I_4)$ [28]				$I_2$ vs $T_2(I_4)$ [28]				$I_2$ vs $T_3(I_4)$ [28]				$I_2$ vs $T_4(I_4)$ [28]			
	m	$\mu$	sd	R												
r-GA*	32.15	3293	>99	6	32.20	68.26	33	6	33.38	3656	>99	6	29.53	57.89	32	5
HE-GA	33.59	94.40	35	5	29.94	46.64	41	5	29.88	37.67	14	3	31.34	78.25	33	6
SS*	34.80	35.66	0.5	3	30.36	33.07	3.7	3	38.85	43.70	9.6	5	<b>28.44</b>	29.69	0.5	4
SS	28.54	44.21	79	4	<b>28.61</b>	35.27	35	4	<b>28.46</b>	<b>28.80</b>	0.1	1	28.57	<b>28.75</b>	0.1	1
CRO*	35.06	35.54	0.2	2	30.25	30.47	0.1	2	39.11	40.66	0.5	4	29.36	29.64	0.1	3
CRO	<b>28.32</b>	<b>28.79</b>	0.3	1	<b>28.61</b>	<b>29.01</b>	0.6	1	28.57	28.82	0.1	2	28.59	28.76	0.1	2

el enfoque de características permite a los métodos obtener mejores resultados mínimos, a expensas de incrementar la varianza. Por otro lado, los resultados de los métodos basados en intensidades (excepto r-GA\*) son más robustos, obteniendo una menor desviación que los métodos de características.

Ambos genéticos tienen un comportamiento inestable, pero alcanzan buenos resultados mínimos. r-GA\* alcanza la última posición del ranking (5.63) debido a obtener los mayores errores en la comparativa. A pesar de su pobre comportamiento, HE-GA es capaz de obtener el mejor resultado mínimo en tres de los dieciséis escenarios, con un ranking de 4.94.

SS\* y SS mejoran considerablemente a los genéticos, con un comportamiento consistente excepto en cuatro escenarios, donde no terminan de converger. Así, los métodos basados en SS alcanzan las posiciones medias del ranking (3.0 y 3.56, respectivamente). Aunque tienen un rendimiento similar en cuanto al ECM, SS mejora a SS\* al obtener mejores resultados mínimos a pesar de su mayor desviación estándar.

En cuanto a nuestras propuestas, CRO\* obtiene mejor ECM medio que ambos métodos basados en SS, pero es incapaz de alcanzar su precisión en valores mínimos. Por otro lado, la adaptación al enfoque de características (CRO) mejora tanto a CRO\* como al actual método del estado del arte, SS. En cuanto al ECM medio, CRO mejora a SS en doce escenarios. Así, CRO\* alcanza la segunda posición con 2.5, mientras que CRO es primero con un ranking de 1.38, gracias a su excelente balance entre exploración y explotación. Ambos enfoques basados en CRO son capaces de mejorar al actual estado del arte en RI, destacando nuestra propuesta basada en características por obtener el mejor rendimiento.

Al aplicar el test estadístico de Friedman obtenemos un resultado de  $\chi^2_F = 92,0$ , con un p-valor correspondiente de  $< 10^{-16}$ . Dado que  $p$  es menor que el nivel de significancia considerado ( $\alpha = 0,01$ ), el test concluye que hay diferencias significativas entre métodos. Complementamos el análisis con el test de Holm (Tabla IV) comparando CRO (control) con el resto de métodos. El p-valor resultante para ambos tests revela que existen diferencias significativas entre CRO y tanto los métodos genéticos como aquellos basados en SS.

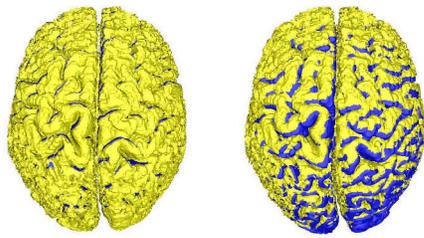
Tabla IV: Ranking de Friedman y resultados estadísticos con CRO como método de control para los test de Bonferroni y Holm, de acuerdo con el valor medio de ECM.

	Ranking	Bonferroni-Dunn p	Holm p
CRO	1.38	-	-
CRO*	2.50	0,44	0,09
SS	3.00	0,07	< 0,05
SS*	3.56	< 0,01	< 0,01
HE-GA	4.94	< 0,01	< 0,01
r-GA*	5.63	< $10^{-10}$	< $10^{-10}$

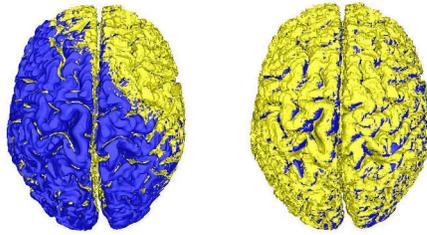
Por último, incluimos un análisis visual de los resultados obtenidos en uno de los escenarios más complejos. La Figura 2 muestra la mejor alineación entre imágenes obtenida por cada algoritmo. Destacamos los resultados de nuestras propuestas basadas en CRO, en especial el enfoque de características, ya que mejoran considerablemente la precisión de la alineación resultante.

## V. CONCLUSIONES

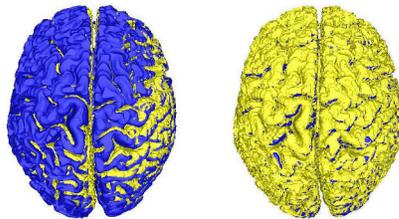
En este trabajo describimos el diseño e implementación de una novedosa técnica bio-inspirada, conocida como CRO, para



HE-GA (51.2) vs. r-GA\* (60.8)



SS (46.9) vs. SS\* (54.3)



CRO (46.8) vs. CRO\* (57.5)

Figura 2: Resultados del solapamiento entre el modelo (azul) y la escena (amarillo). La figura aporta una comparativa de los resultados entre el enfoque de características (izquierda) y de intensidades (derecha) para el escenario  $n^{\circ}11$  ( $I_1$  vs.  $T_3(I_4)$ ). Entre paréntesis se indica el mínimo ECM alcanzado.

resolver el problema de RI médica en 3D de forma robusta y eficiente. En particular, abordamos el problema considerando dos enfoques, usando la distribución de intensidades de las imágenes y un conjunto reducido de puntos característicos, cada uno con diferentes niveles de complejidad. CRO integra en su diseño una estrategia de búsqueda balanceada, que le permite obtener resultados excelentes en diferentes problemas reales. Así, adaptamos CRO al problema de RI siguiendo ambos enfoques y analizamos su comportamiento.

Para evaluar el rendimiento de nuestra propuesta comparamos ambas implementaciones de CRO con algunos de los métodos evolutivos más relevantes de la literatura en RI. Diseñamos un exhaustivo estudio experimental con 16 escenarios de RI mono-modal a partir de cuatro IMRs cerebrales sintéticos, con diferentes niveles de ruido y lesiones. Las imágenes provienen del repositorio BrainWeb (McGill University [9]).

CRO obtiene unos resultados excelentes considerando ambos enfoques de registrado, y mejora a métodos consolidados en RI demostrando gran robustez y eficiencia al abordar problemas de optimización complejos como es el RI médica.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por los proyectos: TIN2015-67661-P, incluyendo al Fondo Europeo de Desarrollo Regional (ERDF), al Ministerio de Economía y TIN2014-54583-C2-2-R, de la Comisión Interministerial de Ciencia y Tecnología (CICYT).

#### REFERENCIAS

- [1] B. Zitová and J. Flusser, "Image registration methods: A survey," *Image and Vision Computing*, vol. 21, no. 11, pp. 977–1000, 2003.
- [2] A. A. Goshtasby, *2-D and 3-D Image Registration*. Wiley Interscience, 2005.
- [3] P. J. Besl and N. D. McKay, "A Method for Registration of 3-D Shapes," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 14, no. 2, pp. 239–256, 1992.
- [4] J. Santamaría, O. Cordón, S. Damas, J. García-Torres, and A. Quirin, "Performance evaluation of memetic approaches in 3D reconstruction of forensic objects," *Soft Computing*, vol. 13, no. 8-9, pp. 883–904, 2009.
- [5] S. Damas, O. Cordón, and J. Santamaría, "Medical Image Registration Using Evolutionary Computation: An Experimental Survey," *IEEE Computational Intelligence Magazine*, vol. 6, no. 4, pp. 26–42, 2011.
- [6] A. Valsecchi, S. Damas, J. Santamaría, and L. Marrakchi-Kacem, "Intensity-based image registration using scatter search," *Artificial Intelligence in Medicine*, vol. 60, no. 3, pp. 151–163, 2014.
- [7] S. Salcedo-Sanz, J. Del Ser, I. Landa-Torres, S. Gil-López, and J. A. Portilla-Figueras, "The coral reefs optimization algorithm: A novel metaheuristic for efficiently solving optimization problems," *The Scientific World Journal*, vol. 2014, pp. 1–15, 2014.
- [8] E. Bermejo, M. Chica, S. Salcedo-Sanz, and O. Cordón, "Coral Reef Optimization for Intensity-based Medical Image Registration," in *IEEE Congress on Evolutionary Computation, CEC 2017 - Proceedings*. IEEE, 2017, pp. 533–540.
- [9] D. L. Collins, A. P. Zijdenbos, V. Kollkian, J. G. Sled, N. J. Kabani, C. J. Holmes, and A. C. Evans, "Design and construction of a realistic digital brain phantom," *IEEE Trans. on Medical Imaging*, vol. 17, pp. 463–468, 1998.
- [10] A. Valsecchi, S. Damas, J. Santamaría, and L. Marrakchi-Kacem, "Genetic algorithms for Voxel-based medical image registration," in *2013 Fourth International Workshop on Computational Intelligence in Medical Imaging (CIMI)*, apr 2013, pp. 22–29.
- [11] M. Takahashi and H. Kita, "A crossover operator using independent component analysis for real-coded genetic algorithms," *Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546)*, vol. 1, pp. 643–649, 2001.
- [12] M. Lozano, F. Herrera, N. Krasnogor, and D. Molina, "Real-coded memetic algorithms with crossover hill-climbing," *Evolutionary computation*, vol. 12, no. 3, pp. 273–302, 2004.
- [13] R. He and P. A. Narayana, "Global optimization of mutual information: application to three-dimensional retrospective registration of magnetic resonance images," *Computerized Medical Imaging and Graphics*, vol. 26, no. 4, pp. 277–292, 2002.
- [14] Salcedo-Sanz, "A review on the coral reefs optimization algorithm: new development lines and current applications," *Progress in Artificial Intelligence*, vol. 6, no. 1, pp. 1–15, 2017.
- [15] O. Monga, S. Benayoun, and O. Faugeras, "From partial derivatives of 3-D density images to ridge lines," in *Proceedings 1992 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 1808. Champaign, Illinois, USA: IEEE, 1992, pp. 354–359.
- [16] S. Klein, M. Staring, K. Murphy, M. A. Viergever, and J. P. W. Pluim, "Elastix: A toolbox for intensity-based medical image registration," *IEEE Trans. on Medical Imaging*, vol. 29, no. 1, pp. 196–205, 2010.

# Registrado de imágenes 3D-2D para identificación forense mediante comparación de radiografías

Oscar Gómez\*, Oscar Ibáñez\*, Andrea Valsecchi\*, Oscar Cordon\* y Tzipi Kahana†

\*Instituto Andaluz Interuniversitario DaSCI (Data Science and Computational Intelligence), Universidad de Granada, España

† Facultad de Medicina, Universidad Hebrea de Jerusalén, Jerusalem, Israel

Emails: ogomez@decsai.ugr.es, oscar.ibanez@decsai.ugr.es, valsecchi.andrea@gmail.com, ocordova@decsai.ugr.es, kahana.tzipi@gmail.com

**Abstract**—La comparación de radiografías es una técnica de identificación forense que conlleva la comparación manual de radiografías ante-mortem (AM) y post-mortem (PM). Sin embargo, éste es un proceso lento y propenso a errores por lo que su utilidad se ve reducida. El objetivo de este trabajo es proponer y validar un nuevo paradigma asistido por ordenador para comparación de radiografías. En concreto, se centra en reproducir de manera automática los parámetros de adquisición de la radiografía AM en una proyección del modelo 3D PM mediante una metodología basada en el registrado de imágenes 3D-2D. Este proceso de registrado será guiado por la silueta de la estructura anatómica utilizada para identificar en la radiografía AM y un modelo 3D PM de la misma. El problema de optimización subyacente es complejo ya que no se puede asumir una inicialización cercana y tampoco se puede depender del valor de intensidad de los píxeles (enfoque tradicional en imagen médica). Para abordarlo se ha utilizado una meta-heurística, differential evolution, y un método clásico que ha sido adaptado para este problema concreto. Se han realizado múltiples experimentos para estudiar la precisión y robustez de la propuesta utilizando imágenes sintéticas de clavículas, rótula y senos frontales obteniendo resultados prometedores.

**Index Terms**—Identificación forense, comparación de radiografías, registrado de imágenes 3D-2D, computación evolutiva.

## I. INTRODUCCIÓN

La identificación forense es de suma importancia en nuestra sociedad [1]. Los métodos principales de identificación son la odontología forense, el análisis de huellas dactilares y el análisis de ADN. Sin embargo, la aplicación de estos métodos no es posible cuando no se dispone de la suficiente información ante-mortem (AM) o post-mortem (PM) debido a la falta de datos por estado de conservación del cadáver y/o la ausencia de muestras AM contra las que comparar. En este aspecto, las técnicas de identificación basadas en el esqueleto (SFI, por sus siglas en inglés, *skeleton-based forensic identification*) pueden suponer la última posibilidad de identificación. Esto es debido a que el esqueleto generalmente sobrevive a procesos de descomposición natural y no natural, como por ejemplo es habitual en escenarios de desastres masivos.

Las técnicas de SFI son usadas para identificación y/o filtrado dependiendo del poder identificativo de cada hueso o cavidad [2]. Dentro de las técnicas de SFI, las más importantes son la superposición craneofacial [3], la reconstrucción facial [4] y la comparación de radiografías (CR). En concreto, CR

[1] es la única técnica SFI considerada primaria por la Interpol (junto con la comparación de implantes quirúrgicos) [5]. En la literatura, numerosas estructuras anatómicas como huesos y cavidades se han mostrado útiles para realizar una identificación positiva [6]. Éstas están localizadas principalmente en la zona del cráneo (p. ej. dientes [7] y los senos frontales [8] y del pecho (p. ej. clavículas [9] y vértebras [10]). Aunque también hay otras fuera de estas regiones tales como los huesos de la mano [11] y la rótula [12], entre muchas otras.

Sin embargo, a pesar de ser el método más empleado y útil en SFI, su aplicación todavía se basa en una comparación manual de los datos AM-PM a través de un proceso de inspección visual que depende por completo de la habilidad y experiencia del experto. Como consecuencia, su utilidad se reduce debido a que es un proceso tedioso y propenso a errores debidos al cansancio del experto.

Guiados por el análisis de la literatura forense, se han distinguido tres etapas consecutivas en proceso automático de identificación mediante CR:

- 1) Obtención de los datos AM de todos los candidatos y el procesado del material PM. Incluye la mejora y segmentación de las imágenes AM y PM.
- 2) Producir una radiografía PM que simule la transformación proyectiva de cada una de las radiografías AM del candidato.
- 3) Toma de decisiones en base a la superposición obtenida, junto con otros factores tales como la calidad de las imágenes o el poder discriminatorio del hueso utilizado.

Pese a la necesidad de métodos automáticos, esta técnica ha sido objeto de pocos trabajos de investigación. En concreto, se han utilizado técnicas de morfometría geométrica, tales como el análisis de la elíptica de Fourier, para la CR de senos frontales [13], bóvedas craneales [14], clavículas [15], y rótulas [12]. El enfoque de los dos primeros trabajos consiste en la segmentación manual del hueso o cavidad en las radiografías AM y PM y finalmente compararlas utilizando el análisis de la elíptica de Fourier. Mientras tanto, los dos últimos se basan en la adquisición de modelos 3D de los huesos PM utilizando un escáner de luz estructurada, pero la decisión final aún implica la comparación de la segmentación de la radiografía AM contra un conjunto predefinido de imágenes obtenidas a través de rotaciones pre-establecidas



del modelo 3D PM. No hay, sin embargo, ningún método automático que busque la mejor proyección posible del modelo 3D.

El proceso de superposición para CR es complejo debido principalmente a dos razones. La primera, la radiografía AM fue tomada en unas condiciones desconocidas y por tanto no se puede asumir una inicialización cercana. La segunda, las intensidades en las imágenes no son fiables o incluso hay escenarios en los que no se dispone de ellas (véase la Sección 2). Esto lleva a que las técnicas habituales de registro de imágenes (RI) 3D-2D no sean adecuadas para CR y se deben investigar técnicas diferentes para resolverlo satisfactoriamente, como la utilización de algoritmos evolutivos [16].

El objetivo de este trabajo es proponer y validar un método asistido por ordenador para realizar la superposición de un modelo 3D de cualquier hueso o cavidad PM y una radiografía AM segmentada. El método sigue una metodología de RI 3D-2D basada en la silueta del hueso o cavidad. Para validar se han utilizado dos tipos de huesos (clavículas y rótulas) y uno de cavidad (senos frontales).

Este artículo se organiza de la siguiente manera. En la sección II se hace una revisión del estado del arte de RI. La sección III describe nuestra propuesta. La sección IV presenta los experimentos realizados junto con sus resultados. Por último en la sección V se presentan las conclusiones de este trabajo.

## II. ANTECEDENTES Y JUSTIFICACIÓN

RI [17], [18] es el proceso de poner dos imágenes en un mismo sistema de coordenadas, donde una imagen se mantiene fija y la otra es transformada. En el escenario 3D-2D, la imagen transformada es siempre la 3D y la 2D se mantiene fija. Los métodos de RI 3D-2D son clasificados según quién el proceso de optimización utilizando intensidades o características de las imágenes.

En imagen médica, los métodos basados en intensidades son los más extendidos debido a que no requieren segmentaciones, las cuales introducen subjetividad y errores. Estos han sido utilizados satisfactoriamente en problemas de registro de Tomografías Computarizadas, TACs, (3D) y radiografías (2D) [19]. Sin embargo en el problema que nos ocupa (CR), los niveles de intensidad han podido cambiar desde el momento de la adquisición de la radiografía y el TAC. Esto se debe a que la densidad de los huesos puede cambiar por muchos motivos provocando un cambio en las intensidades capturadas (p. ej. edad, osteoporosis, tiempo transcurrido desde el fallecimiento, etc). Otro motivo importante es el hecho de que muchos laboratorios forenses hacen uso en la actualidad de escáneres de luz estructurada [20] debido a su gran disponibilidad y bajo coste, mientras que solo unos pocos de ellos tienen TACs. Estas limitaciones descartan los métodos basados en intensidades, dejando únicamente los basados en características. Los antropólogos forenses consideran que la morfología ósea (silueta) es un aspecto fiable para realizar la identificación basada en CR. Por otro lado, no es posible utilizar otras características como puntos homólogos por la imposibilidad de

establecer una correspondencia entre los puntos 3D y 2D. Los datos 3D son el hueso o cavidad PM en forma de un modelo de superficie PM 3D, ya sea que se obtiene al segmentar una imagen volumétrica como una CT o directamente desde un escáner 3D. Los datos 2D son la silueta del hueso en una radiografía AM. Los métodos de RI 3D-2D IR para dominios médicos [21], [22] pueden asumir que trabajan en un entorno controlado. En consecuencia pueden limitar la transformación a solo 6 grados de libertad (trasladaciones y rotaciones) sin tener en cuenta los parámetros relacionados con las distorsiones de perspectiva. Además utilizan inicializaciones cercanas al *Ground Truth* (p. ej. en [22] consideran un error máximo de 20 mm y de rotación de 20 °, de 16 mm en [21], etc). Sin embargo, estas asunciones no son adecuadas para CR. Por supuesto, hay algunas excepciones como Feldman et al. [23] que propuso un método IR 3D-2D basado en la silueta que no depende de las inicializaciones pero es solo aplicable en el caso calibrado (considerando solo 6 DoF). No existe ningún enfoque de RI 3D-2D basado en la silueta que considere 7 grados de libertad sin depender de una inicialización cercana.

## III. REGISTRADO DE IMÁGENES PARA COMPARACIÓN DE RADIOGRAFÍAS

No hay un estándar universal para diseñar un método de RI. No obstante, los métodos de RI suelen tener los siguientes 5 componentes (en la Figura 1 se puede ver un esquema de la propuesta de RI 3D-2D para CR): (1) el modelo 3D (modelo 3D del hueso PM) y una imagen fija (radiografía AM); (2) la transformación proyectiva responsable de generar una proyección 2D del modelo 3D; (3) el conocimiento experto que delimita la transformación proyectiva; (4) una métrica de similitud que mide las similitudes entre la proyección y la imagen fija; y (5) un optimizador que busca los parámetros de la transformación proyectiva según la métrica de similitud.

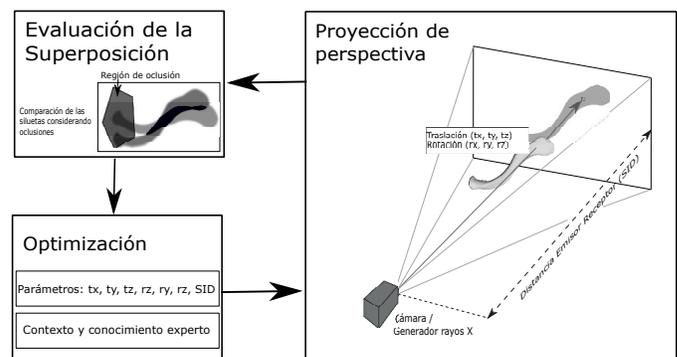


Fig. 1: Esquema de la propuesta de RI 3D-2D para CR.

### A. Datos AM y PM

Las imágenes a registrar son las siguientes:

- La imagen 2D: la radiografía AM.
- El modelo 3D: un modelo 3D de la superficie del hueso o cavidad. Obtenido mediante el uso de un escáner

de luz estructurada del "hueso limpio" o mediante la segmentación del hueso en un TAC.

En esta propuesta, el proceso de RI se guía por la silueta del hueso o cavidad por lo que es necesario su segmentación en ambas imágenes. En la radiografía AM, la silueta puede estar ocluida por otras estructuras. Por ello aparte de la silueta es necesario segmentar una región de oclusión donde el experto tiene dudas (véase la Figura 2). En el caso 3D hay dos escenarios posibles en función de si se parte de un modelo 3D de superficie obtenido con un escáner de luz estructurada o de un TAC. En el primer escenario no es necesario ningún preprocesamiento. Por otro lado, en el TAC los huesos se segmentan fácilmente mediante el uso de las unidades Hounsfield <sup>1</sup>.

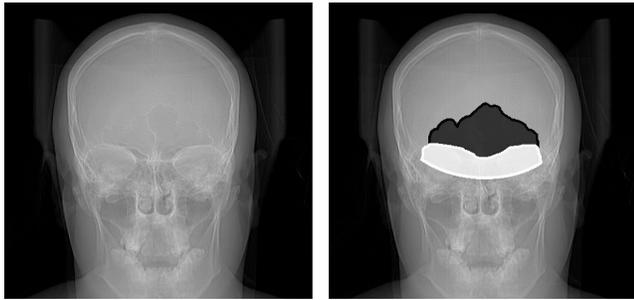


Fig. 2: Radiografía del cráneo: sin segmentar (izquierda), con la segmentación de los senos frontales en negro y la región de oclusión en blanco.

### B. Transformación proyectiva

Una transformación proyectiva es una transformación entre el mundo 3D y una imagen 2D. Las funciones proyectivas son de dos tipos: proyecciones de perspectiva y ortográficas [24].

La transformación que origina una radiografía la modelamos mediante una transformación de perspectiva simple utilizando solo 7 parámetros: 6 parámetros extrínsecos (3 traslaciones y 3 rotaciones de la cámara) y 1 intrínseco (la distancia entre el emisor y el receptor, SID, por sus siglas en inglés, *source image distance*) [25] (véase la Figura 1). La mayoría de trabajos en imagen médica consideran solo 6 parámetros dado que asumen que en un escenario controlado el parámetro SID es conocido [21], [22]. Pero en CR, cómo ya se ha comentado en las secciones anteriores, es necesario considerar los 7 parámetros.

Por otro lado, la transformación ortográfica es un caso particular de la transformación de perspectiva donde la cámara está situada en el "infinito" y por tanto no modela distorsiones de perspectiva. La mayoría de las radiografías tienen distorsiones de perspectiva (a excepción de aquellas con una SID elevada como las imágenes cefalométricas con una SID de 4 metros). No obstante, el estudio del modelo ortográfico merece la pena debido a que matemáticamente es más sencillo y podría ser suficiente para identificar. Esta transformación tiene solo 6 parámetros: 2 traslaciones que representan la posición

<sup>1</sup>Es una escala cuantitativa utilizada en los estudios de TACs para describir los diferentes niveles de radiodensidad de los tejidos humanos.

del centro de la silueta en la imagen 2D, 3 rotaciones y 1 escala que representa el porcentaje de píxeles de la imágenes ocupados por el *bounding box* (el cuadrado delimitador) de la silueta en la imagen.

### C. Parámetros y su delimitación con conocimiento experto

Los parámetros están solo delimitados por el protocolo de adquisición de radiografías [26]. Las radiografías son tomadas con el cuerpo en una posición conocida (posterioranterior o lateral) y la rotación por tanto puede ser delimitada para ambas transformaciones con un margen de error (p. ej.  $\pm 10^\circ$  o  $\pm 20^\circ$  en ángulos de Euler). En la transformación de perspectiva, el protocolo de adquisición también sirve para delimitar la traslación, la SID y también para conocer las dimensiones del receptor y su resolución (píxeles por mm). La traslación en los ejes x e y es delimitada por el ancho y alto del receptor, mientras que la SID del protocolo sirve para delimitar la SID con un rango de error y también la traslación en el eje z ya que el cuerpo se suele colocar pegado al receptor, mientras que en la transformación ortográfica la traslación es delimitada por los límites de la imagen en coordenadas normalizadas (de -1 a 1) y la escala por el porcentaje de píxeles que se espera que ocupe la silueta en la radiografía (desde el 5% al 80%), no requiriendo conocimiento experto. Por último, en el ortográfico no es necesario conocer las dimensiones del receptor ni su resolución.

### D. Métrica de similitud

Para medir las similitudes entre dos siluetas la métrica más utilizada en la literatura es la métrica *DICE* [27]. En este trabajo, la métrica *DICE* ha sido adaptada creando una nueva métrica, *Masked DICE* (véase la Eq. 1), mediante la inclusión de la región de oclusión. La región de oclusión define un área que es ignorada por la métrica permitiendo así solapamientos parciales y obviando regiones dubitativas (incertidumbre en la segmentación). En los casos en los que no haya región de oclusión el valor de la métrica *Masked DICE* será igual al de *DICE*. En el caso particular donde la proyección del hueso esté fuera del campo de visión, el valor de la métrica es fijado a 1.5.

$$\text{Masked DICE} = \frac{2 \cdot |(I_A \setminus M) \cap (I_B \setminus M)|}{|I_A \setminus M| + |I_B \setminus M|} \quad (1)$$

donde  $I_A$  son los píxeles de la silueta del objeto A (el hueso segmentado AM),  $I_B$  son los píxeles del objeto B (la proyección de hueso PM), y  $M$  es la región de oclusión.

### E. Optimizador

El problema de optimización es complejo dado que no se puede hacer uso de las intensidades o de una inicialización cercana, como ya se comentó en las secciones anteriores. Además se asume una alta multimodalidad del espacio de búsqueda. Para abordar el problema se ha estudiado el uso de dos optimizadores diferentes. El primero está basado en un método de optimización numérica llamado BOBYQA [28], que ya ha sido aplicado a problemas de RI. El segundo está basado en *Differential Evolution* (DE) [29], metaheurística que



ha mostrado un gran comportamiento en los problemas de optimización global [30].

### 1) EG-BOBYQA

Varios métodos de optimización numérica (tanto de búsqueda lineal tales como Nelder-Mead, BFGS y LBFGS, cómo de región de confianza tales como Levenberg-Marquardt y BOBYQA) han sido probados para afrontar este problema de RI utilizando la librería DLIB [31]. El que mejores resultados obtuvo en los experimentos preliminares fue BOBYQA.

Sin embargo, pese a ser el mejor, sus resultados en la experimentación preliminar fueron insuficientes debido a que mostró una gran dependencia de la inicialización, especialmente con los parámetros relacionados con la rotación. Para afrontar este problema, se ha propuesto EG-BOBYQA (*estimation grid-BOBYQA*). Este método consiste en realizar diferentes ejecuciones de BOBYQA con diferentes inicializaciones mediante el uso de un *grid* en los tres parámetros de la rotación (limitando el número de evaluaciones de BOBYQA para que sea computacionalmente abordable). Además para cada configuración del *grid*, los parámetros de la traslación y la escala son estimados en la transformación ortográfica. Hay que buscar un compromiso entre la granularidad del *grid* y el tiempo de ejecución, ya que por ejemplo un *grid* con pasos de un grado en los tres ejes de rotación es computacionalmente inabordable incluso para el menor de los rangos de rotación considerados (de  $20^\circ$  en cada eje). Este problema se resuelve utilizando varios *grid* de forma iterativa reduciendo el rango de rotación y el tamaño del paso hasta alcanzar un paso menor a un grado. El paso inicial ha sido establecido de manera experimental en un cuarto del rango de rotación y en cada iteración es dividido entre cuatro, mientras que el rango de rotación es reducido de la siguiente forma [mejor rotación -  $\frac{paso}{2}$ , mejor rotación +  $\frac{paso}{2}$ ]. Finalmente la mejor solución del último *grid* es mejorada de nuevo utilizando BOBYQA sin establecer un número límite de evaluaciones.

Este optimizador es solo aplicable a la transformación ortográfica dado que la estimación de la escala y la traslación no puede realizarse en la transformación perspectiva dado que dependen tanto de la traslación en eje z como de la SID.

### 2) Differential Evolution

DE es una metaheurística propuesta por Storn y Price [29]. Se ha aplicado con éxito a problemas de optimización multimodales debido a su gran robustez, rápida convergencia y al reducido número de parámetros a fijar [32]. Además también se ha utilizado en problemas de RI 3D-3D [33]. Los parámetros a fijar de DE son los siguientes:  $F$  (controla la tasa de mutación),  $P_c$  (controla la tasa de recombinación),  $n$  (tamaño de la población) y  $m$  (número de generaciones).

## IV. EXPERIMENTOS

Los experimentos realizados están dedicados al estudio de la precisión y robustez de los dos optimizadores en problemas sintéticos de CR con dos tipos de huesos, clavículas y rótulas, y un tipo de cavidad, senos frontales, en casos positivos, es decir, el caso AM y el PM pertenecen a la misma persona.

Todos los experimentos se han realizado en un servidor con 12 nodos, cada uno con un Intel Core i7 4930k 3.4 GHz con el sistema operativo Ubuntu 16.04.

### A. Generación del dataset

Para medir la capacidad de RI 3D-2D de las propuestas se han utilizado casos sintéticos, cada uno compuesto por un modelo de superficie 3D y una proyección de perspectiva (2D) aleatoria (dentro del rango de los parámetros). Esto permite evaluar objetivamente la calidad de una superimposición incluso en escenarios con oclusiones debido a que la proyección sin oclusiones también es conocida.

En este experimento se han utilizado datos sintéticos de clavículas, rótulas y senos frontales. En concreto, se han escaneado 10 clavículas y 10 rótulas (procedentes del laboratorio de antropología física de la Universidad de Granada) con un escáner Artec *Spider<sup>TM</sup>* 3D, y 10 senos frontales han sido segmentados manualmente de TACs (procedentes del Hospital de Castilla la Mancha) usando 3D Slicer 4.5.0-1 (véase la sección III.A). Para cada uno de los 30 modelos 3D se han generado 5 proyecciones de perspectiva aleatorias dentro de los rangos de la Tabla I. Además, el tamaño del receptor para senos frontales y rótulas es de 240 mm  $\times$  300 mm y la SID es de 1000 mm, y en clavículas de 430 mm  $\times$  350 mm y 1800 mm (resultado en imágenes de 750  $\times$  900 píxeles y de 1290  $\times$  1050, respectivamente). Para cada una de las 150 imágenes simuladas, dos imágenes adicionales han sido generadas añadiendo oclusiones en la silueta del 15% y 30% con sus respectivas zonas de incertidumbre. En total se han generado 450 casos positivos de CR con sus respectivos GTs.

TABLE I: Rango de los parámetros para la transformación de perspectiva delimitados según los protocolos de adquisición [26]

Parámetro	Hueso/Cavidad		
	Senos frontales	Rótulas	Clavículas
$t_x$ (mm)	[-125, 125]	[-125, 125]	[-210, 210]
$t_y$ (mm)	[-150, 150]		[-175, 175]
$t_z$ (mm)	[700, 1100]		[700, 1900]
$r_x, r_y, y r_z$ (grados)	[-10°, 10°], [-20°, 20°]		
SID (mm)	[9000, 1100]		[1600, 1900]

### B. Diseño experimental

Los parámetros de los optimizadores se han fijado en base a una experimentación preliminar, siendo sus mejores configuraciones las siguientes. En BOBYQA la región de confianza inicial se fija en 0.05. En DE 100 individuos, 50000 evaluaciones, una probabilidad de cruce  $P_c$  de 0.5, y un F de 0.5. Con DE, se han realizado 16 ejecuciones independientes de cada experimento, dado que DE se basa en un proceso estocástico, para poder estudiar tanto su precisión como robustez. La inicialización de cada ejecución es aleatoria en todo el rango de los parámetros. Para ambos, se ha establecido un criterio de parada cuando el error de solapamiento es inferior al 0.01% de los píxeles.

En total se han llevado a cabo 2700 experimentos que se desglosan de la siguiente manera:

- 1) Transformación ortográfica: 2 optimizadores (EG-BOBYQA y DE), 2 rangos de rotación ( $\pm 10^\circ$   $\pm 20^\circ$ ),

con los 450 casos simulados (véase que todos los casos fueron generados con la transformación de perspectiva). Un total de 1800 experimentos.

- 2) Transformación perspectiva: 1 optimizador (DE), 2 rangos de rotación ( $\pm 10^\circ$  y  $\pm 20^\circ$ ), con los 450 casos simulados. Un total de 1800 experimentos. Con esta transformación no se ha podido probar EG-BOBYQA por los motivos vistos en la sección III.E.

### C. Resultados

Los resultados obtenidos se muestran en la Tabla II para las métricas *Masked DICE* y mRPD (error medio de la distancia de retroproyección, para más información véase [34]). Las métricas *Masked DICE* y mRPD están correlacionadas según el test de correlación de Pearson [35] (obteniendo un coeficiente de 0.780), lo cual indica que *Masked DICE* es una buena métrica para guiar el proceso de optimización en CR. También se ve que la transformación de perspectiva obtiene siempre mejores resultados que la ortográfica, lo cual se confirma con el test de Wilcoxon [36] y el del signo [37] obteniendo unos valores p de  $2.2 \cdot 10^{-16}$  y  $8.6 \cdot 10^{-203}$ , respectivamente. Esta diferencia puede explicarse ya que solo la transformación de perspectiva puede reproducir las distorsiones de perspectiva presentes en los casos. Por último, DE obtiene siempre mejores resultados tanto en media como en desviación estándar (sd) que EG-BOBYQA, lo cual se confirma también con el test de Wilcoxon y el de signo obteniendo unos valores p de  $2.2 \cdot 10^{-16}$  y de  $9.2 \cdot 10^{-110}$ .

TABLE II: Resumen de los resultados bajo las métricas DICE y mRPD según hueso o cavidad, transformación y optimizador.

Hueso	Optimizador	Transf.	Masked DICE		mRPD (mm)	
			media	sd	media	sd
Clavícula	DE	Orto.	0.015	0.011	12.128	14.442
		Persp.	<b>0.001</b>	<b>0.003</b>	<b>0.055</b>	<b>0.088</b>
	EG-BOBYQA	Orto.	0.044	0.025	12.714	14.373
		Persp.	0.014	0.016	11.981	16.270
Rótula	DE	Orto.	0.035	0.020	12.148	16.892
		Persp.	<b>0.005</b>	<b>0.008</b>	<b>0.761</b>	<b>1.544</b>
	EG-BOBYQA	Orto.	0.014	0.055	8.471	3.571
		Persp.	<b>0.001</b>	<b>0.003</b>	<b>0.028</b>	<b>0.067</b>
Senos frontales	DE	Orto.	0.029	0.034	8.285	3.399
		Persp.	<b>0.001</b>	<b>0.003</b>	<b>0.028</b>	<b>0.067</b>
	EG-BOBYQA	Orto.	0.029	0.034	8.285	3.399
		Persp.	<b>0.001</b>	<b>0.003</b>	<b>0.028</b>	<b>0.067</b>

La robustez de ambos optimizadores es mejorable dado que tienen algunas ejecuciones con errores muy altos (un 40%<sup>2</sup> con Masked DICE y 60 mm con mRPD). Sin embargo, el error mínimo del DE (es decir, el mejor resultado de las 16 ejecuciones) es siempre inferior a 0.5% con Masked DICE y de 0.1 mm con mRPD con las tres estructuras anatómicas para la transformación de perspectiva. Mientras que para el ortográfico es de 3% y 1 mm, respectivamente. Además ni la oclusión ni el rango de rotación han mostrado una influencia significativa en la precisión, afectando ligeramente a la robustez. Por último, también puede verse que existe una gran diferencia según la estructura anatómica, siendo los senos frontales los que obtienen mejores resultados seguidos de las clavículas, y por último de las rótulas.

<sup>2</sup>La métrica DICE multiplicada por 100 es equivalente al porcentaje de píxeles no coincidentes entre dos siluetas.

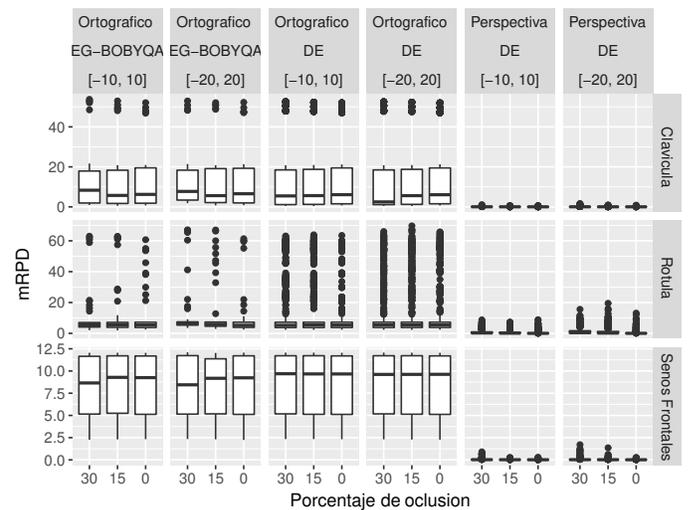


Fig. 3: Boxplots del error mínimo obtenido según el hueso o cavidad, transformación y optimizador bajo la métrica mRPD.

El principal punto débil de esta propuesta es el alto tiempo de ejecución necesario para obtener los resultados (30 minutos de media), haciendo difícil volver a ejecutar DE cuando éste obtiene una mala superimposición. Esto se debe al alto número de evaluaciones que necesita realizar el optimizador.

En resumen, DE obtiene buenas superposiciones con ambas transformaciones, los dos rangos de rotación y los diferentes niveles de oclusión, pero solo siendo robusto con los senos frontales debido a la singularidad de su silueta.

### V. CONCLUSIONES

La contribución de este trabajo ha sido abordar el problema del RI 3D-2D para CR basándose únicamente en la silueta del hueso o cavidad. Se han considerado dos optimizadores (EG-BOBYQA y DE) y dos transformaciones proyectivas (ortográfica y perspectiva). Se han obtenido resultados prometedores con un error de solapamiento inferior al 2% de los píxeles entre la silueta AM y la proyección del modelo 3D PM encontrada por el optimizador. A nivel general, DE ha ganado a EG-BOBYQA en todos los sentidos tanto en precisión como en robustez. Además la transformación de perspectiva también ha sido mejor que la ortográfica mostrando la importancia de poder reproducir las distorsiones de perspectiva. Estos resultados varían significativamente según el hueso o la cavidad. Los peores resultados han sido obtenidos con las rótulas presumiblemente por su baja singularidad con un error promedio de 0.761 mm y 1.5 % de píxeles mal superpuestos de acuerdo con las métricas mRPD y Masked DICE, respectivamente. Con clavículas por otro lado se han logrado errores promedio de 0.055 mm y 0.2 %, respectivamente. Mientras que los mejores resultados han sido obtenidos con los senos frontales con un error promedio de 0,028 mm y 0,2 % de píxeles mal superpuestos, respectivamente, debido a su singularidad. Estos resultados concuerdan con el uso que las rótulas y clavículas tienen en identificación limitado principalmente al filtrado de



casos [9], [12], mientras que los senos frontales han sido utilizados directamente para identificación [8].

En conclusión, se ha logrado automatizar el proceso de RI necesario para una aplicación adecuada de la técnica CR con reproducibilidad, objetividad y alta precisión. El principal inconveniente de esta propuesta es el tiempo de cálculo requerido para obtener las superposiciones (30 minutos en promedio por superposición). El primer trabajo futuro es la realización de un escenario  $n$  contra  $n$  con casos positivos y negativos que permitirá comprobar si los errores obtenidos son suficientes para identificación. Además de realizar un estudio comparativo de diferentes metaheurísticas de rápida convergencia [38] para reducir el tiempo de ejecución de la propuesta.

#### AGRADECIMIENTOS

Esta investigación ha sido subvencionada por el Ministerio de Economía y Competitividad de España bajo el proyecto NEWSOCO [TIN2015-67661-P], y por el departamento andaluz de Innovación, Ciencia y Empresa [TIC2011-7745], que incluye fondos europeo para el desarrollo de la región. El trabajo del Sr. Gómez ha sido financiado por el MECD mediante una beca FPU [FPU14/02380]. El trabajo del Dr. Ibáñez ha sido financiado por el MINECO mediante una beca Juan de la Cierva-Incorporación [JCI-2014-22433].

#### BIBLIOGRAFÍA

- [1] M. J. Thali, B. Brogdon, M. D. Viner, Forensic radiology, CRC Press, 2002.
- [2] M. Page, J. Taylor, M. Blenkin, Uniqueness in the forensic identification sciences—fact or fiction?, *Forensic Science International* 206 (1) (2011) 12–18.
- [3] M. I. Huete, O. Ibáñez, C. Wilkinson, T. Kahana, Past, present, and future of craniofacial superimposition: Literature and international surveys, *Legal Medicine* 17 (4) (2015) 267 – 278.
- [4] C. Wilkinson, Forensic facial reconstruction, Cambridge University Press, 2004.
- [5] Interpol, Disaster victim identification guide, Available at: <https://www.interpol.int/Media/Files/INTERPOL-Expertise/DVI/DVI-Guide-20082>.
- [6] T. Kahana, J. Hiss, Identification of human remains: forensic radiology, *Journal of Clinical Forensic Medicine* 4 (1) (1997) 7 – 15.
- [7] I. Pretty, A look at forensic dentistry - part 1: The role of teeth in the determination of human identity, *British Dental Journal* 190 (7) (2001) 359–366.
- [8] G. Quatrehomme, P. Fronty, M. Sapanet, G. Grévin, P. Baillet, A. Ollier, Identification by frontal sinus pattern in forensic anthropology, *Forensic Science International* 83 (2) (1996) 147–153.
- [9] C. Stephan, A. Winburn, A. Christensen, A. Tyrrell, Skeletal identification by radiographic comparison: Blind tests of a morphoscopic method using antemortem chest radiographs, *Journal of Forensic Sciences* 56 (2) (2011) 320–332.
- [10] T. Kahana, L. Goldin, J. Hiss, Personal identification based on radiographic vertebral features, *The American Journal of Forensic Medicine and Pathology* 23 (1) (2002) 36–41.
- [11] M. G. Koot, N. J. Sauer, T. W. Fenton, Radiographic human identification using bones of the hand: A validation study, *Journal of Forensic Sciences* 50 (2) (2005) 263–268.
- [12] E. Niespodziewanski, C. N. Stephan, P. Guyomarc'h, T. W. Fenton, Human identification via lateral patella radiographs: A validation study, *Journal of Forensic Sciences* 61 (1) (2016) 134–140.
- [13] A. M. Christensen, Testing the reliability of frontal sinuses in positive identification, *Journal of Forensic Sciences* 50 (1) (2005) 18–22.
- [14] A. B. Maxwell, A. H. Ross, A radiographic study on the utility of cranial vault outlines for positive identifications, *Journal of Forensic Sciences* 59 (2) (2014) 314–318.
- [15] C. N. Stephan, B. Amidan, H. Trease, P. Guyomarc'h, T. Pulsipher, J. E. Byrd, Morphometric comparison of clavicle outlines from 3d bone scans and 2d chest radiographs: a shortlisting tool to assist radiographic identification of human skeletons, *Journal of Forensic Sciences* 59 (2) (2014) 306–313.
- [16] S. Damas, O. Cordón, J. Santamaría, Medical image registration using evolutionary computation: An experimental survey, *IEEE Computational Intelligence Magazine* 6 (4) (2011) 26–42.
- [17] P. Markelj, D. Tomaževič, B. Likar, F. Pernuš, A review of 3D/2D registration methods for image-guided interventions, *Medical Image Analysis* 16 (3) (2012) 642–661.
- [18] F. P. Oliveira, J. M. R. Tavares, Medical image registration: a review, *Computer Methods in Biomechanics and Biomedical Engineering* 17 (2) (2014) 73–93.
- [19] P. Markelj, D. Tomazevic, F. Pernus, B. Likar, Robust gradient-based 3-D/2-D registration of CT and MR to x-ray images, *IEEE Transactions on Medical Imaging* 27 (12) (2008) 1704–1714.
- [20] S. Damas, O. Cordón, O. Ibáñez, J. Santamaría, I. Alemán, M. Botella, F. Navarro, Forensic identification by computer-aided craniofacial superimposition: a survey, *ACM Computing Surveys* 43 (4) (2011) 27.
- [21] D. B. Russakoff, T. Rohlfing, K. Mori, D. Rueckert, A. Ho, J. R. Adler, C. R. Maurer, Fast generation of digitally reconstructed radiographs using attenuation fields with application to 2D-3D image registration, *IEEE Transactions on Medical Imaging* 24 (11) (2005) 1441–1454.
- [22] J. Jomier, E. Bullitt, M. Van Horn, C. Pathak, S. R. Aylward, 3D/2D model-to-image registration applied to TIPS surgery, in: *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, 2006, pp. 662–669.
- [23] J. Feldmar, N. Ayache, F. Betting, 3D-2D projective registration of free-form curves and surfaces, in: *Computer Vision, 1995. Proceedings., Fifth International Conference on, IEEE, 1995*, pp. 549–556.
- [24] R. Hartley, A. Zisserman, Multiple view geometry in computer vision, Cambridge University Press, 2003.
- [25] D. Mery, X-ray Testing, Springer International Publishing, Cham, 2015, pp. 1–33.
- [26] K. L. Bontrager, J. Lampignano, Textbook of radiographic positioning and related anatomy, Elsevier Health Sciences, 2013.
- [27] T. Sørensen, A method of establishing groups of equal amplitude in plant sociology based on similarity of species and its application to analyses of the vegetation on danish commons, *Kongelige Danske Videnskaberne Selskab* 5 (1948) 1–34.
- [28] M. J. Powell, The BOBYQA algorithm for bound constrained optimization without derivatives, Cambridge NA Report NA2009/06, University of Cambridge, Cambridge, UK, 2009.
- [29] R. Storn, K. Price, Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces, *Journal of Global Optimization* 11 (4) (1997) 341–359.
- [30] A. K. Qin, X. Li, Differential evolution on the CEC-2013 single-objective continuous optimization testbed, in: *2013 IEEE Congress on Evolutionary Computation*, 2013, pp. 1099–1106.
- [31] D. King, Dlib c++ library, Available at: <http://dlib.net>.
- [32] U. Chakraborty, Advances in differential evolution, Vol. 143, Springer, 2008.
- [33] J. Santamaría, S. Damas, J. M. García-Torres, O. Cordón, Self-adaptive evolutionary image registration using differential evolution and artificial immune systems, *Pattern Recognition Letters* 33 (16) (2012) 2065–2070.
- [34] E. B. van de Kraats, G. P. Penney, D. Tomazevic, T. Van Walsum, W. J. Niessen, Standardized evaluation methodology for 2-D-3-D registration, *IEEE Transactions on Medical Imaging* 24 (9) (2005) 1177–1189.
- [35] K. Pearson, Note on regression and inheritance in the case of two parents, *Proceedings of the Royal Society of London* 58 (1895) 240–242.
- [36] E. A. Gehan, A generalized wilcoxon test for comparing arbitrarily singly-censored samples, *Biometrika* 52 (1-2) (1965) 203–223.
- [37] W. J. Dixon, A. M. Mood, The statistical sign test, *Journal of the American Statistical Association* 41 (236) (1946) 557–566.
- [38] Q. Chen, B. Liu, Q. Zhang, J. Liang, P. Suganthan, B. Qu, Problem definition and evaluation criteria for CEC 2015 special session and competition on bound constrained single-objective computationally expensive numerical optimization, Computational Intelligence Laboratory, Zhengzhou University, China and Nanyang Technological University, Singapore.

# Ajuste de un modelo de crecimiento de tumores de vejiga mediante PSO y predicción con incertidumbre

Clara Burgos-Simón\*, Juan-Carlos Cortés\*, José-Ignacio Hidalgo<sup>†</sup>, David Martínez-Rodríguez\*, Rafael-J. Villanueva\*

\*Instituto Universitario de Matemática Multidisciplinar,  
Universitat Politècnica de València, Valencia, Spain

Email: clabursi@upv.es, jccortes@upv.es, damarro3@upv.es, rjvillan@upv.es

<sup>†</sup>Departamento de Arquitectura de Computadores y Automática  
Universidad Complutense de Madrid, Madrid, Spain

Email: hidalgo@ucm.es

**Resumen**—El cáncer de vejiga es uno de los cánceres más comunes en el sistema urinario, siendo una neoplasia altamente agresiva. Generalmente, el pronóstico no es bueno y es muy difícil determinar la evolución para un paciente determinado. En este trabajo proponemos un modelo matemático dinámico que describe el crecimiento del tumor de vejiga y la evolución de la respuesta inmune. Este modelo está personalizado para un solo paciente, y se determinan los valores de los parámetros del modelo a través de una calibración que utiliza el algoritmo de optimización Particle Swarm Optimization. Debido a la incertidumbre de la evolución del tumor, utilizando los parámetros del modelo calibrado podemos predecir el tamaño del tumor y la evolución de la respuesta inmune en los próximos meses asumiendo tres escenarios diferentes: favorable, desfavorable y neutro.

**Keywords:** Cáncer de vejiga, Modelo dinámico, Cuantificación de la incertidumbre, Calibración del modelo, Particle Swarm Optimization.

## I. INTRODUCCIÓN

El cáncer de vejiga es uno de los cánceres más comunes del sistema urinario y es una neoplasia altamente agresiva [1], [2]. El 80 % de los pacientes diagnosticados con este cáncer presenta un carcinoma no invasivo que puede ser extirpado mediante una Resección Trans Uretral (RTU), que es un procedimiento endoscópico para eliminar el tumor de la parte interna de la vejiga [3]. El cáncer de vejiga se caracteriza por su recurrencia en más de la mitad de los pacientes, pues el tumor reaparece después de un tiempo y puede progresar a cáncer músculo-invasivo. Es en este estadio es cuando los tratamientos se vuelven más agresivos, y pueden incluir la extirpación de la vejiga para evitar la diseminación del cáncer a otras partes del cuerpo [4].

El pronóstico del cáncer de vejiga generalmente no es bueno y, después de la RTU, el tratamiento habitual es la instilación de bacilos Calmette-Guérin (BCG) dentro de la vejiga con la idea de que la BCG se fije a las células tumorales residuales, estimulando la respuesta inmune del paciente contra estas células infectadas para eliminarlas completamente [5].

En este trabajo proponemos un modelo matemático para estudiar la evolución del cáncer y la respuesta inmune desde el momento en el que se diagnostica. En este modelo consideraremos el protocolo terapéutico de tratamiento y lo adaptaremos a los datos disponibles que suelen utilizar los médicos para conocer el estado de la enfermedad y procurar un tratamiento adecuado y un seguimiento apropiado a cada paciente.

Una vez establecido el modelo, realizaremos un calibrado para determinar los parámetros del modelo que replican la evolución de un paciente particular. Para la calibración, utilizaremos una versión del algoritmo de optimización PSO.

Una vez calibrado el modelo, utilizaremos los parámetros para hacer una predicción a corto plazo de la evolución del tamaño del cáncer y de la respuesta inmune del paciente. Esta predicción, debido a la escasez de datos, se realizará teniendo en cuenta 3 posibles escenarios: favorable, neutro y desfavorable.

Aunque es natural en el contexto matemático-computacional realizar predicciones una vez obtenida la calibración, en el contexto médico resulta muy innovador debido al poco conocimiento que se tiene sobre la evolución de esta enfermedad en cada paciente.

## II. DATOS DISPONIBLES Y CONSTRUCCIÓN DEL MODELO

Habitualmente, un paciente va a urgencias hospitalarias o al médico de cabecera cuando orina sangre (hematuria). El paciente es derivado al servicio de urología donde, mediante ecografía o citoscopia, se confirma si hay un tumor. En caso de haberlo, empieza el seguimiento y el tratamiento. Este trabajo se ha realizado conjuntamente con doctores del Hospital Universitario y Politécnico La Fe de Valencia [6].

Los médicos han recolectado tejidos biológicos de pacientes que sufren cáncer de vejiga pT1G3, uno de los tipos llamados superficiales. El protocolo dicta la realización de una RTU para extirpar el tumor o tumores, y posteriormente administrar instilaciones de BCG, repitiendo el ciclo hasta que el paciente sane completamente (no hay más recurrencias) o reaparezca el



cáncer aumentando su tamaño y penetrando en el músculo de la vejiga de forma que haya que aplicar otros tratamientos más agresivos, entre los que puede haber incluso la extirpación de la vejiga.

Con la idea de investigar el posible interés de esta técnica para pronóstico y seguimiento de pacientes, hemos seleccionado de la base de datos del hospital los datos correspondientes a un paciente, que llamaremos paciente X, y que se resumen en la tabla I.

Fecha	Procedimiento	Tamaño (mm)	Células inflamatorias/campo
01/Mar/2012	Ecografía	3-5	-
14/Jun/2012	RTU	25	260
15/Feb/2015	Citoscopia	1-2	-
28/Abr/2015	RTU	5	515
30/Jan/2017	Citoscopia	20	-
14/Mar/2017	RTU	30-35	508

Tabla I

DATOS DEL PACIENTE X, QUE TUVO LOS PRIMEROS SÍNTOMAS EN MARZO DE 2012. DESDE ENTONCES, SE LE HAN PRACTICADO AL PACIENTE X TRES RTU.

Además de los procedimientos relacionados en la tabla I, al paciente X se le han administrado 3 tratamientos de instilaciones de BCG que empezaron los días 10/Ago/2012, 26/May/2015 y 27/Abr/2017. La dosis de las instilaciones que se administran en la vejiga consisten en 81 ml de colonias de BCG, instiladas cada semana durante un periodo de seis semanas.

Hemos adaptado el modelo introducido en [7] a los datos disponibles y a la práctica clínica y protocolos del Hospital La Fe. En una primera etapa, el tumor crece y no se administra ningún tratamiento hasta que se realiza la RTU. En esta etapa, sólo hay interacción entre las células tumorales y las inflamatorias, que constituyen la respuesta del sistema inmune global contra el tumor. Después de que en la RTU se reseccionen los tumores de la vejiga, al cabo de unas semanas empieza la administración del tratamiento de BCG. Desafortunadamente, la limpieza completa de células tumorales durante la RTU es imposible debido a la teoría de la siembra [8], por lo que las células tumorales residuales siguen creciendo. Sin embargo, con la administración de la BCG se pretende eliminar estas células residuales debido a que el sistema inmune genera una respuesta específica más agresiva y efectiva contra las células tumorales infectadas por la BCG.

La evolución de estas interacciones se modela mediante el siguiente sistema de ecuaciones en diferencias:

$$E(t+1) = E(t) - \mu_2 E(t) + \alpha T_u(t) + p_4 E(t) B(t) - p_5 E(t) T_u(t), \quad (1)$$

$$T_u(t+1) = T_u(t) - p_2 B(t) T_u(t) - p_6 E(t) T_u(t) + k T_u(t), \quad (2)$$

$$T_i(t+1) = T_i(t) - p_3 E(t) T_i(t) + p_2 B(t) T_u(t), \quad (3)$$

$$B(t+1) = B(t) - \mu_1 B(t) - p_1 E(t) B(t) - p_2 B(t) T_u(t) + b(t), \quad (4)$$

donde  $E(t)$  es el número medio de células inflamatorias por campo de visión del microscopio,  $T_u(t)$  es el diámetro

del tumor en milímetros,  $T_i(t)$  es el diámetro del tumor de células infectadas por la BCG,  $B(t)$  los mililitros de BCG en la vejiga y  $b(t)$  los mililitros de BCG instilados en una o varias dosis, en el instante temporal  $t$ .

El parámetro  $k$  describe la tasa de crecimiento del tumor,  $\alpha$  la tasa de crecimiento de las células inflamatorias,  $\mu_1$  es la tasa de mortalidad natural de la BCG y  $\mu_2$  es la tasa de mortalidad natural de las células inflamatorias.

Los parámetros que describen la interacción entre los distintos tipos de células son:  $p_1$  es la tasa de muerte de BCG debido a las células inflamatorias;  $p_2$  es la tasa de infección de las células tumorales por la BCG;  $p_3$  es la tasa de mortalidad de células tumorales infectadas, debido a la BCG;  $p_4$  es el crecimiento de células tumorales por la acción de la BCG;  $p_5$  es la tasa de mortalidad de células inflamatorias por su interacción con células tumorales no infectadas; y  $p_6$  representa la tasa de mortalidad de las células tumorales por las células inflamatorias.

### III. CALIBRACIÓN

Para encontrar los parámetros del modelo que hagan que las salidas del modelo estén lo más cerca posible a los datos de la tabla I en los instantes de tiempo correspondientes, definimos la siguiente función de ajuste  $F$ :

**Input.** Valor de los parámetros a sustituir en el modelo ( $k, \alpha, \mu_1, \mu_2, p_1, p_2, p_3, p_4, p_5, p_6$ ).

**Paso1.** Sustituir los valores de los parámetros en el modelo (1)-(4).

**Paso2.** Ejecutar el modelo y extraer los valores devueltos por el modelo para el tamaño del tumor y para el número de células inflamatorias por campo en los mismos instantes temporales en los que tenemos datos en la tabla I.

**Paso3.** Calcular el error cuadrático medio entre las salidas del modelo del Paso 2 y los datos de la tabla I.

La calibración del modelo se ha hecho en etapas porque el protocolo no es un proceso continuo debido a la extracción brusca del tumor mediante la RTU. Además, no todos los parámetros se consideran constantes en el tiempo. La respuesta inmune relacionada con la tasa de crecimiento  $p_4$  y la tasa de eficacia  $p_6$ , se va a considerar variable en el tiempo.

La primera etapa será desde 01/Mar/2012 hasta la primera RTU. La segunda etapa es hasta la segunda RTU y la tercera hasta la tercera RTU.

Vamos a minimizar la función  $F$  en cada etapa, determinando los valores de los parámetros del modelo utilizado el algoritmo rPSO [9]. Se trata de un algoritmo bio-inspirado basado en el intercambio de información entre las diferentes partículas que forman el enjambre. La función objetivo (en nuestro caso, la función a minimizar) es evaluada para cada partícula, donde las partículas son vectores formados por los valores de los parámetros del modelo. En cada iteración, actualizamos los valores de la posición de las partículas dentro del espacio de parámetros mediante las siguientes expresiones:

$$pos_{i+1} = pos_i + vel_i, \quad (5)$$

$$vel_{i+1} = U(0, 1) * w * vel_i + U(0, 1) * c_1 * (p_{i,mejor} - pos_i) + U(0, 1) * c_2 * (g_{mejor} - pos_i). \quad (6)$$

donde:

- $U(0,1)$  es una muestra de una distribución uniforme entre los valores  $[0, 1]$ . Este valor es muestreado de forma independiente para cada meta-parámetro dentro de la función, para cada partícula dentro del enjambre y para cada iteración dentro del proceso.
- $p_{i,mejor}$  es la posición de la mejor evaluación de la función para cada partícula individual del enjambre (mejor local).
- $g_{mejor}$  es la posición de la mejor evaluación de la función realizada por cualquiera de las partículas que forman el enjambre durante todo el proceso (mejor global).

Junto con las ecuaciones descritas, al proceso se le añade una componente de mutación para evitar que las partículas converjan en un mínimo local en lugar del global. Este proceso se realiza de la siguiente manera:

- una partícula se rechaza y se genera una completamente nueva con un 10 % de probabilidad;
- si la partícula no ha sido rechazada, con un 10 % de probabilidad se le aplica una mutación.

Se han realizado diversas pruebas con números diferentes de partículas, siendo el número que mejores resultados nos ha dado el de 60 partículas. También se han realizado diversas pruebas con el valor de los meta-parámetros  $w$ ,  $c_1$  y  $c_2$ , siendo los valores finalmente utilizados  $w=0.73$ ,  $c_1=1.5$  y  $c_2=1.5$ .

#### IV. RESULTADOS

Los parámetros del modelo obtenidos en la calibración son los que se muestran en la tabla II.

Parámetro	Valor	Parámetro	Valor
$k$	0.01563	$T_u(RTU_1)$	0,02
$\alpha$	0.005	$p_4(RTU_1)$	1e-4
$\mu_1$	0.8	$p_6(RTU_1)$	1.62e-5
$\mu_2$	0.0005	$T_u(RTU_2)$	0.02
$p_1$	8e-5	$p_4(RTU_2)$	5.6e-4
$p_2$	1e-3	$p_6(RTU_2)$	6.3e-6
$p_3$	1e-4		
$p_4$	0.0		
$p_5$	0.0		
$p_6$	0.0		
$T_u(0)$	5.0		
$E(0)$	260		

Tabla II

VALORES DE LOS PARÁMETROS DEL MODELO CALIBRADOS PARA EL PACIENTE X. NÓTESE QUE LOS PARÁMETROS  $p_4$  Y  $p_6$  CAMBIAN CON EN CADA ETAPA. LOS VALORES QUE ACOMPAÑAN A  $RTU_1$  Y  $RTU_2$  CORRESPONDEN A PARÁMETROS VARIABLES TRAS LAS  $RTU_1$  Y  $RTU_2$ , RESPECTIVAMENTE.

En la figura 1, se puede ver el resultado de la calibración, en la de arriba la respuesta inmune y en la de abajo el tamaño del tumor. Las subidas bruscas en forma de dientes de sierra en la gráfica de la respuesta inmune son debidas a las dosis semanales de instilaciones de BCG. Las caídas en la gráfica del tamaño del tumor, corresponden a cada RTU.

Debido a la incertidumbre en la evolución futura, con el fin de predecir la dinámica del cáncer de vejiga, se han considerado tres escenarios diferentes: favorable, neutral y desfavorable. En el escenario favorable la respuesta del sistema inmune es mayor que la segunda etapa. El escenario neutral

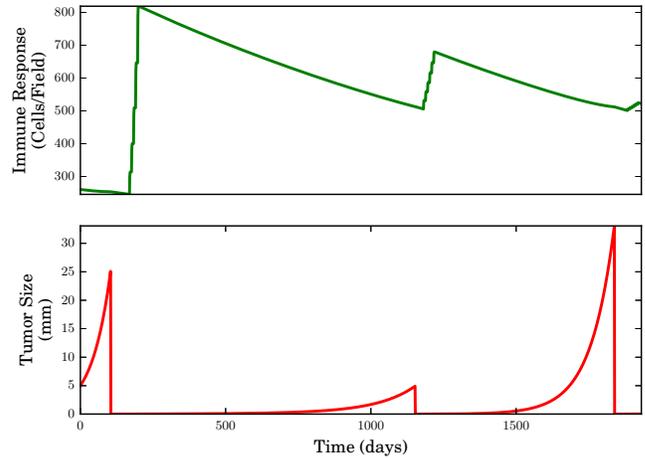


Figura 1. Gráficas con la evolución de la respuesta inmune (arriba) y del tamaño del tumor (abajo) con los parámetros obtenidos en la calibración del modelo.  $t = 0$  corresponde al 01/Mar/2012.

consiste en la misma respuesta del sistema inmune como en la tercera etapa, es decir, la respuesta del sistema inmunitario permanece constante. El escenario desfavorable se basa en el hecho de que la respuesta del sistema inmunitario disminuye en la misma proporción que disminuyó desde la segunda a la tercera fase.

En las figuras 2, 3, 4, se muestran los diferentes escenarios. La predicción empieza desde la línea negra vertical.

En el escenario favorable, el tratamiento con BCG tiene un resultado positivo y el tumor ya no crece más. En el escenario neutral, se estima que ocurrirá una recurrencia del cáncer con un tumor del tamaño de 5 mm que se prevé para el 15 de agosto de 2018. En el escenario desfavorable, la recurrencia del cáncer de vejiga con un tumor del tamaño de 5 mm se prevé para el 25 de mayo de 2018.

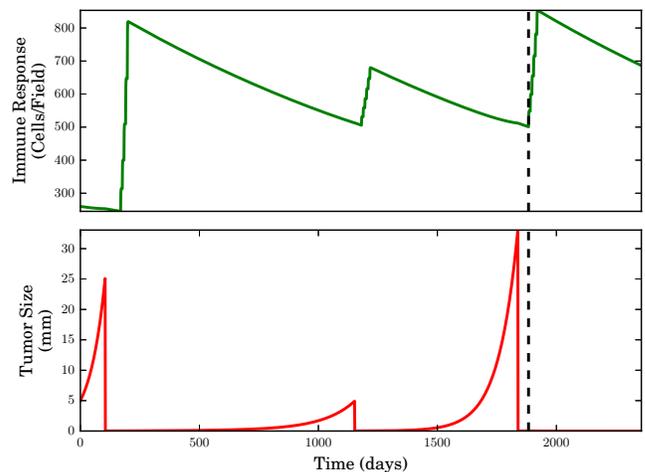


Figura 2. Escenario favorable. La BCG acaba con el tumor.

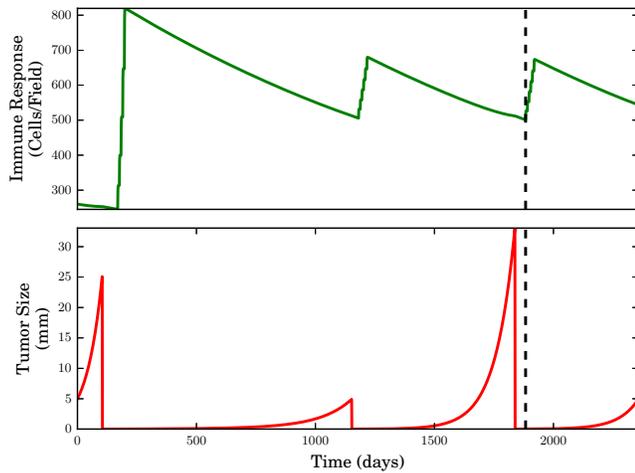


Figura 3. Escenario neutro. Se espera un tumor de 5mm para el 15 de agosto de 2018.

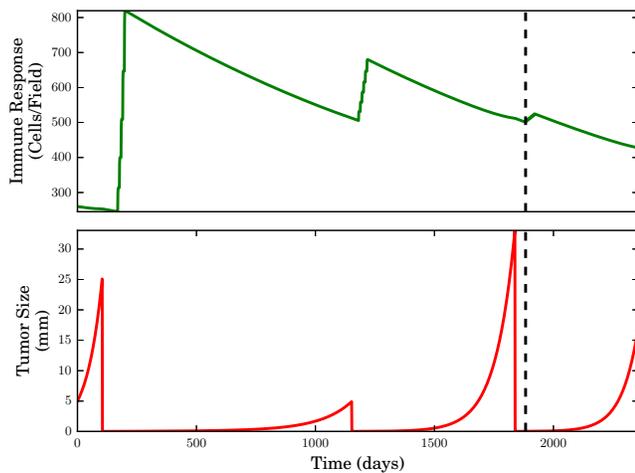


Figura 4. Escenario desfavorable. Se espera un tumor de 5mm para el 25 de mayo de 2018.

## V. CONCLUSIONES

En este trabajo presentamos un modelo dinámico para describir la evolución de un tumor de la vejiga en un paciente. El modelo se ha calibrado en varias etapas y los parámetros obtenidos nos permiten dar un pronóstico sobre el crecimiento del tumor en los próximos meses en tres escenarios: favorable, desfavorable y neutro. Que nosotros sepamos, éste es el primer acercamiento de este tipo. Los resultados parecen prometedores y ha creado expectación en el equipo médico con el que colaboramos debido al desconocimiento de la evolución de este tipo de cáncer en cada paciente.

Cuando tengamos más datos disponibles, seremos capaces de verificar la validez de nuestro enfoque, de realizar predicciones personalizadas a cada paciente más precisas y mejores, dando herramientas a los médicos para administrar tratamientos, para programar las revisiones de seguimiento y, en el futuro, para determinar mejores estrategias para mejorar la salud del paciente, su calidad de vida y evitar las recidivas

del tumor.

## VI. AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto del Ministerio de Economía y Competitividad MTM2017-89664-P y GenObIA-CM con referencia (S2017/BMD-3773) financiado por la Comunidad de Madrid y cofinanciado con Fondos Estructurales de la Unión Europea y Ministerio de Economía y Competitividad TIN2014-54806-R (HERACLES).

## REFERENCIAS

- [1] Official Site for Spanish Medic Oncology Society, <https://www.seom.org>, accessed: 08/05/2018.
- [2] R. T. Greenlee, M. B. Hill-Harmon, T. Murray, M. Thun, *Cancer statistics, 2001*, CA: A Cancer Journal for Clinicians 51 (1) (2001) 15–36. doi: 10.3322/canjclin.51.1.15. URL <https://doi.org/10.3322/canjclin.51.1.15>
- [3] R. Devere White, E. Stapp, *Predicting prognosis in patients with superficial bladder cancer*, ONCOLOGY 12 (12) (1998) 1717–1723. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0005479569&partnerID=40&md5=a865e77b1a2c890bf2985b1517d7e3b6>
- [4] S. Holmang, H. Hedelin, C. Anderstrom, S. L. Johansson, *The relationship among multiple recurrences, progression and prognosis of patients with stages TA and T1 transitional cell cancer of the bladder followed for at least 20 years*, The Journal of Urology 153 (6) (1995) 1823–1827. doi:10.1016/s0022-5347(01)67321-x. URL [https://doi.org/10.1016/s0022-5347\(01\)67321-x](https://doi.org/10.1016/s0022-5347(01)67321-x)
- [5] G. Redelman-Sidi, M. S. Glickman, B. H. Bochner, *The mechanism of action of BCG therapy for bladder cancer—a current perspective*, Nature Reviews Urology 11 (3) (2014) 153–162. doi:10.1038/nrurol.2014.15. URL <https://doi.org/10.1038/nrurol.2014.15>
- [6] Official Site for Hospital Universitari i Politècnic La Fe, Valencia, Spain, <http://www.hospital-lafe.com>, accessed: 07/05/2018.
- [7] S. Bunimovich-Mendrazitsky, E. Shochat, L. Stone, *Mathematical model of BCG immunotherapy in superficial bladder cancer*, Bulletin of Mathematical Biology 69 (6) (2007) 1847–1870. doi:10.1007/s11538-007-9195-z. URL <https://doi.org/10.1007/s11538-007-9195-z>
- [8] A. Wein, L. Kavoussi, A. Novick, A. Partin, C. Peters, *Campbell-Walsh Urology*, Campbell-Walsh Urology, Elsevier Health Sciences, 2011. URL <https://books.google.es/books?id=W1aeyJD46kIC>
- [9] C. Jacob, N. Khemka, *Particle swarm optimization in Mathematica. an exploration kit for evolutionary optimization*, IMS'04, Proc. Sixth International Mathematica Symposium, Banff, Canada.

# On the Use of Fitness Sharing in Studying the Genetic Code Optimality

José Santos

Department of Computer Science,  
University of A Coruña, A Coruña, Spain  
Email: jose.santos@udc.es

Ángel Monteagudo

Department of Computer Science,  
University of A Coruña, A Coruña, Spain  
Email: angel.minsua@udc.es

**Abstract**—Since the canonical genetic code is not universal several theories arose to explain the evolution to its present form. Different computational methods were applied to analyze the optimality level of the canonical code organization, including our previous works using evolutionary computing in the problem. We discuss here the possibilities that the use of the classical fitness sharing technique provides for obtaining knowledge about the fitness landscape involved in the optimization of the genetic code.

## I. INTRODUCTION

The canonical genetic code (CGC), present in most superior organisms, establishes the association between codons and amino acids. In the canonical code there are 64 codons of three bases that encode 20 amino acids. Thus, the genetic code is redundant, since several codons codify the same amino acid. However, the canonical code is not universal, since there are other different associations between codons and amino acids. Mitochondrial DNA is an exception example. The exceptions show that the code could evolve in its origin, and it is an open question how the code evolved to the present form (the CGC).

Since other codes could appear, several models of hypothetical genetic codes were considered, with different associations between codons and amino acids. Considering only the present form of a genetic code with codons of three bases, if the codon set of the CGC is maintained, allowing only swaps of amino acids between the 20 codon sets, the possible codes are 20! ( $2.43 \cdot 10^{18}$ ). Without that restriction, in the sense that every codon can codify every amino acid, the number of alternative codes is really huge, larger than  $1.51 \cdot 10^{84}$ .

In this research there are basically three theories about the reasons regarding the evolution of the genetic code: i) The stereochemical theory establishes that codon assignments are dictated by physicochemical affinity between amino acids and the cognate codons, ii) the co-evolution theory states that a set of precursor amino acids passed part or all of their codon domain to the biosynthetically produced amino acids, and iii) the physicochemical or error minimization theory states that the main factor in the code's evolution was the minimization of the adverse effects of mutations.

In this last error minimization theory there are two different alternatives to assess the level of optimization of the CGC:

1. The statistical approach considers random alternative codes and compares the CGC against the average optimization

quality of those codes [1]. The results of the works in this alternative tend to indicate that the CGC is quite better optimized with respect to random codes.

2. The engineering approach, which compares the CGC against the average random codes and with respect to better codes (typically obtained with local search algorithms) [2]. This alternative shows that the CGC has a certain level of optimization, but is still far from optimal.

In these alternatives, the “quality” of a hypothetical code is defined taking into account the consequences of all possible mutations in the codons. A mutation in a codon base can change the amino acid codified, which can take a serious consequence on the resultant protein. Usually, it is considered a property (or group of properties) of the codified amino acid, like the polar requirement (hydrophobicity), since it is the most important one in defining the folding of the protein. The quality is defined as the Mean Square (MS) of the difference of the property values of the corresponding amino acids before and after the mutation. This is averaged for all base mutations of all codons. The best code would be the one that minimizes MS, that is, the consequences of the mutations (with the lowest consequence on the phenotype, i.e., the proteins).

We introduced the possibility of evolutionary computation to discover better genetic codes [3], with a classical genetic algorithm (GA) (with *ad hoc* operators depending on the genetic code model of alternative codes), studying the level of optimality reached by the CGC in the huge landscapes considered, and taking into account aspects like the different mutation probability of transversion and transition mutations in the codon bases, or the biases in mutation probability in the three codon bases. In [4] we extended the analysis using a model of possible genetic codes that considers the known codon reassignments. Depending on the genetic code model and those commented aspects, the optimization level of the CGC varies, but in all cases is far from optimal, and in agreement with the engineering approach.

Since there is a discussion about whether the CGC is located in a local minimum (or close to a minimum) in the quality landscape and whether the landscape has a multimodal nature, in a recent work [5] (which is summarized here) we introduced the use of the classical Fitness Sharing (FS) technique [6] in the evolutionary algorithm to inspect that possible multimodal nature. FS allows the division of the population into different

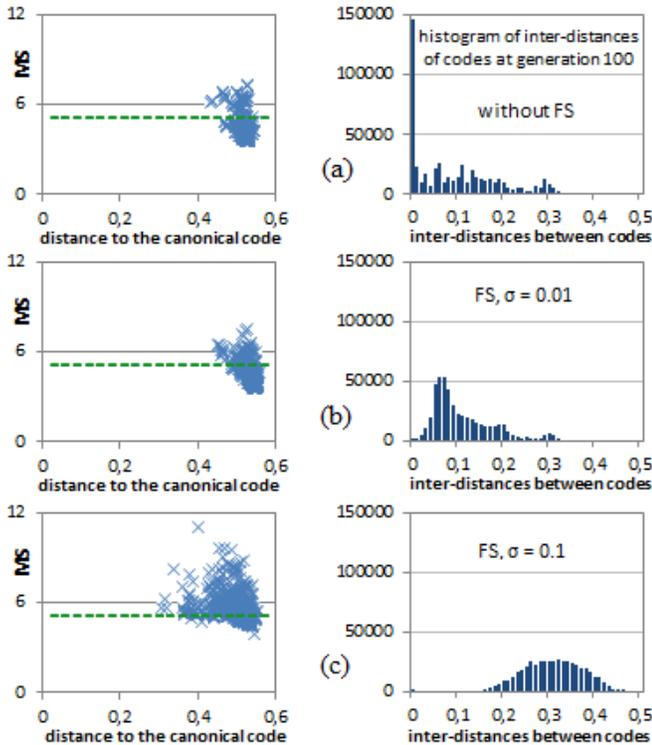


Fig. 1. Left: MS value of the hypothetical codes of the final genetic population vs. their distances to the canonical code and using restrictive codes. Right: Histograms of interdistances of final evolved codes.

subgroups according to the similarity of the individuals, groups that perform a simultaneous search in the best found promising areas (global or local minima) of the search landscape.

The use of fitness sharing serves for two purposes: i) to have an indirect view of the huge search landscape and to locate the CGC in relation to the best possible codes that could be obtained. ii) Given the nature of the landscape obtained in i), to determine the difficulty of evolution of hypothetical genetic codes in such a landscape.

## II. RESULTS WITH A RESTRICTIVE CODE MODEL

An example of a run of the evolutionary algorithm is presented here. All the details about the GA implementation (genetic operators, encoding of hypothetical genetic codes) are in [5]. We present results of an example run with and without the use of fitness sharing and with a restrictive model of hypothetical codes. In this model, the pattern of synonymous coding found with the CGC is maintained, that is, the 21 CGC non-overlapping sets of codons are fixed (20 sets correspond to the amino acids and one set to the 3 stop codons). The 20 amino acids are randomly assigned to one of the 20 sets while the same 3 stop codons are fixed as in the CGC.

Figure 1 corresponds to a run of the GA without FS and with FS with two values of the parameter “sharing radius” ( $\sigma_{share} = 0.01$  and  $\sigma_{share} = 0.1$ ), which controls the extent of sharing [6]. In Figure 1, subfigures at the left, the  $x$ -axis corresponds to the distance of each encoded code to the CGC whereas the  $y$ -axis corresponds to the code MS value. These graphs correspond to the final populations at generation 100

in 3 cases: (a) without FS, (b) FS with  $\sigma_{share} = 0.01$  and (c) FS with  $\sigma_{share} = 0.1$ . The figures at the right correspond to the histograms of interdistances between the encoded codes at that final generation. The distance  $d_{ij}$  between two codes  $i$  and  $j$  is measured taking into account the difference in polar requirement between the amino acids encoded in the same positions by both population codes, normalized in  $[0,1]$ .

The distances of the population (1000 individuals) to the canonical code vary in a range between 0.3 and 0.6. Many of the evolved codes are better adapted than the canonical code (the dashed line represents the MS value of the CGC), showing that these better codes are far from the CGC. There is not any clustering of individuals, independently of the value of  $\sigma_{share}$ , which indicates that there are not deep local minima and that the CGC is not located in an area of a deep local minimum.

Moreover, the CGC was introduced in the initial population in the 3 cases. In all runs the CGC disappears from the population in few generations (as shown in [5]), even with the use of fitness sharing, which is another evidence that the CGC is not located in an area corresponding to a deep local minimum. The interdistances (Figure 1, right part) show that, without FS, the individuals are close to the best solution, whereas the solutions are more spread in the search landscape with larger values of  $\sigma_{share}$  when FS is used. Since there are not interdistance values close to 0 in the histogram (i.e., no clusters), both graphs (with FS) indicate that the landscape does not present clear localized areas of deep local peaks, as well as that the CGC is not located in one of such areas.

## III. CONCLUSION

The main conclusion to be drawn from the results is that the fitness landscape, although is clearly rugged, does not have a multimodal nature with deep localized areas of low MS values and separated by barriers of high MS values. Therefore, the fitness landscape considered in the error minimization theory does not explain how the canonical code ended its evolution in an area that does not correspond to a deep local minimum.

## ACKNOWLEDGMENT

This work was funded by Xunta de Galicia (project GPC ED431B 2016/035), Xunta de Galicia (“Centro singular de investigación de Galicia” accreditation 2016-2019 ED431G/01) and the European Regional Development Fund (ERDF).

## REFERENCES

- [1] S. Freeland, R. Knight, and L. Landweber, “Measuring adaptation within the genetic code,” *Trends in Biochemical Sci.*, vol. 25(2), pp. 44–45, 2000.
- [2] M. Di Giulio, “The origin of the genetic code,” *Trends in Biochemical Sciences*, vol. 25(2), p. 44, 2000.
- [3] J. Santos and A. Monteagudo, “Study of the genetic code adaptability by means of a genetic algorithm,” *Journal of Theoretical Biology*, vol. 264(3), pp. 854–865, 2010.
- [4] J. Santos and A. Monteagudo, “Simulated evolution applied to study the genetic code optimality using a model of codon reassignments,” *BMC Bioinformatics*, vol. 12:56, 2011.
- [5] J. Santos and A. Monteagudo, “Inclusion of the fitness sharing technique in an evolutionary algorithm to analyze the fitness landscape of the genetic code adaptability,” *BMC Bioinformatics*, vol. 18:195, 2017.
- [6] D. Goldberg and J. Richardson, “Genetic algorithms with sharing for multimodal function optimization,” *Proceedings 2nd International Conference on Genetic Algorithms*, pp. 41–49, 1987.



**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 10:

COMPUTACIÓN EVOLUTIVA:  
FUNDAMENTOS Y MODELOS I







# Toolkit for the Automatic Comparison of Optimizers (TACO): Herramienta *online* avanzada para comparar metaheurísticas

1<sup>st</sup> Daniel Molina

Departamento de Ciencias de la Computación e I.A.  
Universidad de Granada  
Granada, España  
dmolina@decsai.ugr.es

2<sup>nd</sup> Antonio LaTorre

DATSI, ETSIINF  
Centro de Simulación Computacional  
Universidad Politécnica de Madrid  
Madrid, España  
atorre@fi.upm.es

**Resumen**—El campo de las metaheurísticas es un campo en continua innovación, en donde los investigadores proponen frecuentemente nuevas propuestas, propuestas que tienen que ser adecuadamente comparadas con el estado-del-arte para probar su efectividad. El uso de benchmarks estándar permite comparar directamente los resultados de los algoritmos entre sí, pero incluso esas comparaciones suponen un proceso laborioso y repetitivo que consume gran parte del proceso de investigación en metaheurísticas. En este trabajo proponemos Toolkit for the Automatic Comparison of Optimizers, TACO, una herramienta *online* avanzada para comparar metaheurísticas, que además de almacenar los resultados de distintos algoritmos competitivos para distintos benchmarks (para usarlos como algoritmos de referencia), es capaz de realizar de forma automática una variedad de comparaciones. De hecho, permite comparar no sólo los algoritmos previamente almacenados, sino también los resultados de nuevos algoritmos sin necesidad de registrarse, e incluso para funciones específicas (no limitado a un benchmark concreto). Consideramos que es una herramienta muy útil para todo tipo de investigaciones en metaheurísticas. Como prueba de su conveniencia, ofrecemos una instancia de demostración de sus características, sobre la que se han realizado las distintas comparaciones que incluimos en este trabajo.

**Index Terms**—Comparativa de algoritmos, Herramienta web, Optimización Global de Alta Dimensionalidad.

## I. INTRODUCTION

El uso de metaheurísticas es muy común en problemas de optimización de diversa índole, ya que son algoritmos capaces de obtener muy buenos resultados en un tiempo limitado [1]. Este interés conduce a que se presenten un número continuo de propuestas cada año en la literatura científica. Un paso necesario para que la comunidad científica pueda considerar una propuesta es el de realizar una adecuada validación experimental en la que, para un conjunto de problemas (*benchmark*), se compare la propuesta presentada con distintos algoritmos, especialmente algoritmos del *estado-del-arte*.

Habitualmente, la comparativa implica realizar una misma experimentación tanto con la propuesta como con los algoritmos de referencia (usados para comparar). Afortunadamente, cada vez está más consolidado el uso de *benchmarks* específicos en los que se fijan a priori las condiciones experimentales, por lo que el problema se reduce a comparar los resultados de

la propuesta con los otros algoritmos publicados, simplificando el proceso. Sin embargo, realizar una correcta experimentación sigue siendo una tarea muy laboriosa y costosa en tiempo. El investigador no sólo tiene que recopilar los resultados de su propuesta, sino también los de los algoritmos con los que se va a comparar. Y la recopilación de datos es sólo el primer paso: los datos deben normalizarse (obtener la mismas medidas y con la misma frecuencia), agruparse (en funciones similares para su análisis), organizarse (en tablas), y analizarse (mediante una o varias medidas estadísticas o visualizaciones). Y, por cada cambio en alguno de los algoritmos (mejora de la propuesta, por ejemplo), estos pasos deben repetirse, incrementando el tiempo dedicado a las comparativas.

En este trabajo proponemos *Toolkit for the Automatic Comparison of Optimizers*, TACO, accesible en <https://tacolab.org> (con código disponible), una herramienta *online* avanzada que combina un repositorio públicamente accesible de resultados para distintos *benchmarks* con una herramienta de análisis modular que permite comparar fácilmente los resultados de distintos algoritmos, tanto para la fase de desarrollo del algoritmo como para la obtención de tablas y gráficas finales para la publicación del trabajo. Entre sus características más interesantes están:

- Soporte para distintos benchmarks, cada uno con sus propias propiedades: funciones asociadas y grupos de funciones, tamaño del problema (dimensión), hitos, etc.
- Diseño modular: La aplicación permite analizar según una serie de informes, que pueden ser generales, o ser específicos para un determinado *benchmark*.
- Repositorio de resultados de distintos algoritmos: La base de datos no sólo almacena estadísticas comunes (como media, mínimo, ...) que puedan recogerse de colecciones, sino que pueden almacenar todos los resultados para realizar comparaciones estadísticas que lo requieran.
- Definición flexible de informes: La aplicación ofrece una capa de abstracción de gráficas (líneas, barras, etc.) para permitir incorporar nuevos informes
- Exportación de datos. Para poder usarse en publicaciones

tanto las gráficas como las tablas se pueden guardar localmente para usarlas en distintos formatos. Las gráficas se pueden guardar en los formatos bitmap PNG y JPEG, en informes PDF, o formato vectorial SVG. Las tablas en formato tanto Excel (para posterior análisis) como Latex (para incluirlo directamente en publicaciones). En las tablas se puede elegir el número de cifras decimales que se desean obtener (aunque en Excel no es importante, en Latex sí lo es para poder insertarlo directamente en las publicaciones).

TACO está inspirada en una herramienta previa [2] pero resuelve muchas de sus limitaciones.

- No requiere que el usuario almacene previamente los resultados para comparar. Cualquier usuario (sin registrarse) puede ejecutar su análisis simplemente subiendo los resultados en un formato soportado, y comparar entre sí tanto los de la base de datos como los indicados por fichero.
- TACO permite que los usuarios identificados posean repositorios propios, con un catálogo de resultados de carácter privado. Los usuarios pueden solicitar hacerlos públicos cuando el *paper* esté publicado.
- Una tecnología y diseño mucho más flexible y modular, para ir incorporando mejoras.

Existen otras herramientas de análisis, discutidas en [3], como jMetal<sup>1</sup> o MOEA framework<sup>2</sup>. Sin embargo, en esos casos el proceso de análisis suele estar asociado con el propio entorno (*framework*) de optimización, limitando su uso. TACO se centra en comparar resultados ya obtenidos, sin interferir en la forma de programar/ejecutar el código.

Otro aspecto muy importante de la herramienta es que no sólo está pensada como herramienta de soporte a investigadores para comparar su propuesta con otros algoritmos, sino que también está ideada para organizadores de competiciones (de hecho, surgió a partir de esa necesidad). Gracias a su diseño modular, es bastante directo incorporar una nueva sesión especial o competición de manera sencilla. Además, se puede usar también para que los propios participantes comparen sus propuestas con los algoritmos de referencia de la competición. Una vez que la competición haya tenido lugar, se pueden hacer públicos los resultados de todos los algoritmos participantes.

Este trabajo está organizado de la siguiente manera: La sección II describe brevemente la arquitectura de la aplicación. En la sección III se muestra el esquema de funcionamiento. En la sección IV resumimos algunas opciones disponibles y mostramos unas capturas relevantes. La sección V repasa el diseño modular de informes, con ejemplos concretos. Finalmente, en la sección VI resumimos las principales conclusiones obtenidas.

## II. ARQUITECTURA

La aplicación web está construida como una página estática que mediante llamadas Ajax pide los datos dinámicos y

<sup>1</sup><https://jmetal.github.io/jMetal/>

<sup>2</sup><http://moeframework.org/>

los visualiza usando JavaScript. Para ello, usa las siguientes tecnologías webs:

- HTML5, CSS3 y Javascript (Vue.js<sup>3</sup> framework) en el *frontend*.
- El entorno Python Flask<sup>4</sup> y SQL Alchemy<sup>5</sup> como *backend*.
- Intercambio de datos entre ambos mediante peticiones AJAX y mensajes JSON.

El *framework* Vue.js es usado para dar una imagen dinámica de la web, pidiendo por AJAX toda la información (*benchmarks*, dimensionalidad, algoritmos, informes, etc.) al *backend* (con almacenamiento local para incrementar el rendimiento). Este diseño permite incorporar fácilmente la herramienta en otra aplicación web, desde páginas estáticas a sistemas CMS como Wordpress o similares.

## III. MODOS DE TRABAJO

Existen dos formas de trabajar, se pueden comparar usando los resultados de un benchmark estándar del sistema, o usando un conjunto de funciones (es muy útil para comparar para funciones distintas, o un subconjunto de funciones).

### III-A. Comparando con un benchmark propio

Este es el caso más sencillo, en el que se desea únicamente comparar entre sí distintos resultados que posee el usuario.

En este caso, el usuario debe ofrecer sus datos por medio de un fichero de entrada aceptado con los distintos resultados de cada algoritmo para un número de funciones. Un ejemplo sería un Excel con tantas columnas como funciones, con los resultados de cada algoritmo en su propia hoja del Excel. Adicionalmente se puede establecer una columna *milestone* para guardar resultados intermedios. Una vez subido el fichero, el usuario selecciona el tipo de comparación de entre las disponibles de forma genérica (descritos en la sección V) y procede al análisis.

### III-B. Comparando con un benchmark estándar

Una sesión típica empieza seleccionando el *benchmark* sobre el que se quiere comparar. Luego, el usuario decide el tamaño del problema (si hay más de uno), y selecciona de una lista de algoritmos cuáles quiere comparar. Además, el usuario puede subir un fichero con datos de algoritmos propios para incorporarlos a la comparativa. Una vez elegidos todos los datos, el usuario selecciona el tipo de comparación de entre las disponibles (descritas en la sección V) y procede al análisis.

El modelo de datos está diseñado en torno al concepto de *benchmark*. Cada *benchmark* está asociado con una tabla diferente en donde se almacenan los resultados de los algoritmos. Esto permite que distintos *benchmarks* puedan tener un distinto número de funciones de forma sencilla. Agrupada en torno a los benchmarks, se almacena la siguiente información:

- Dimensión: algunos *benchmarks* poseen un mismo tamaño del problema, y otros plantean para las mismas

<sup>3</sup><https://vuejs.org/>

<sup>4</sup><http://flask.pocoo.org/>

<sup>5</sup><https://www.sqlalchemy.org/>



funciones/problemas distintos valores, para medir la escalabilidad del algoritmo.

- Hitos: un *benchmark* puede almacenar los resultados finales o en distintos momentos de la ejecución del algoritmo. El sistema guarda información de cada hito.
- Grupos o categorías de funciones: Los *benchmarks* pueden tener problemas/funciones con distintas características, y eso permite analizar los resultados por grupos de funciones (como comparar separadamente comportamiento en problemas unimodales y multimodales).
- Informes: Aparte de los informes disponibles para todos los *benchmark*, un *benchmark* puede tener asociado alguno específico (en particular, en las competiciones de alta dimensionalidad se usa un ranking específico, de la F1). Se muestra, para cada *benchmark*, el conjunto de posibles informes asociados.

#### IV. FRONTEND

Las Figuras 1, 2 y 3 resumen el flujo de trabajo más completo de la aplicación. La primera información cuando un usuario se conecta es un texto explicativo, donde se le pide que seleccione el *benchmark* de su interés de una lista desplegable (Figura 1), obtenida de forma dinámica. Una vez seleccionado el *benchmark*, la aplicación consulta al servidor los valores de dimensión para que el usuario elija de forma similar (si hubiese más de uno; si no, como en la Figura 1, se selecciona automáticamente y se va al paso siguiente).

The process is simple:

1. Select the wanted benchmark.
2. Select the dimension (if there is more of one for the benchmark).
3. Select the algorithm to compare. You can select from the Database and/or add results from an Excel file.
4. Select the report.
5. Push the button **Compare**.

#### Select Benchmark

Select the benchmark used for comparison:



Figura 1: Selección del *benchmark* para la comparación. La lista desplegable es dinámica.

Luego, se listan los algoritmos almacenados en la base de datos asociados a ese *benchmark* (públicos o de ese usuario, si está identificado), y para esa dimensión (ver Figura 2) y los muestra con un *checkbox* para seleccionarlos. El usuario puede seleccionar de la lista los que desea, y, opcionalmente, subir un fichero con la información de sus propios algoritmos (TACO admite ficheros tanto en formato *csv* como *xls*) y un nombre. Como cada *benchmark* podría tener un formato diferente, encima del formulario para subir el fichero se muestra un enlace con un fichero Excel de ejemplo para el *benchmark* seleccionado y se puede consultar una plantilla para rellenar. Aunque el usuario puede indicar el nombre del algoritmo en el formulario, también puede indicarlo en el fichero de entrada en su propia columna (o en varias hojas), lo cual permite enviar en un único fichero los resultados de

distintos algoritmos, que serán comparados entre sí y con el resto de algoritmos seleccionados. En este punto, el usuario escogerá el tipo de informe de entre los disponibles que, como ya se indicó, dependerá del tipo de *benchmark* elegido.

#### CEC'2013 Large Scale Global Optimization

Benchmark for the Large Scale Global Optimization competitions.

Dimension value: 1000

#### Algorithms to compare

- BICCA
- CC-CMA-ES
- DECC-G
- DEEPSO
- MLSHADE-SPA
- MOS
- NEW RESTART
- SACC
- SHADEILS
- VMODE

Figura 2: Selección de los algoritmos. El usuario puede elegir de la lista y/o subir un fichero con los suyos.

#### Algorithms to compare

- BICCA
- CC-CMA-ES
- DECC-G
- DEEPSO
- MLSHADE-SPA
- MOS
- NEW RESTART
- SACC
- SHADEILS
- VMODE

If you want to compare existing results with your own proposal, set a Excel or CSV file with the results (opti the required format is indicated [here](#)

PROPOSAL  or .xls) to upload

Select the Report:  Precision

Figura 3: Selección del informe de la comparación. La lista de informes disponibles depende del *benchmark* elegido.

Por último, para lanzar el análisis basta con pulsar en el botón *Compare*. En las siguientes secciones detallamos los distintos tipos de informes soportados (hasta el momento), y ejemplos del tipo de análisis que la aplicación permite.

#### V. TIPOS DE INFORMES

El modelo de informes de TACO ha sido particularmente diseñado para ser flexible. Existen informes asociados a cada *benchmark* que pueden dividirse en las siguientes categorías:

- Informes de propósito general, accesibles para todos los *benchmarks*. Ejemplos de éstos serían tablas comparativas de estadísticas comunes (media, ranking), gráficas de convergencia, o algunas comparativas estadísticas.

- Específicos para un *benchmark*, ya que algunos pueden necesitar informes específicos (con medidas particulares). Un ejemplo de esto, ya incluido, es el informe usado en las competiciones de alta dimensionalidad (*LSGO competitions at IEEE CEC*), que asigna a cada algoritmo un número de puntos en función de su *ranking*, y se suman para valorar la bondad de cada algoritmo. Este informe es muy específico de esa comunidad de usuarios, y tiene poco sentido que esté disponible para otros *benchmarks*.

Esta primera versión de TACO incluye:

- Tres informes de tipo general: Comparación de medias, ranking medios, y gráficas de convergencia. Actualmente se están desarrollando comparativas estadísticas que esperamos estén disponibles en el momento del congreso.
- Un informe específico: El ya descrito usando el criterio de la F1 para el CEC'2013 de alta dimensionalidad.

A continuación los describimos muy brevemente, mostrando ejemplos reales usando las competiciones de optimización real del CEC'2017 [4], y la competición de alta dimensionalidad del CEC'2013 [5].

#### V-A. Informe comparativo de medias

Es el más sencillo. Computa la media de cada función y algoritmo, y muestra las medias para cada hito en una tabla, destacando la menor media, como se puede observar en la Figura 4. Además de remarcar la mejor media, incluye una línea resumen al final. Como toda tabla, los botones permiten exportar los datos en Excel y en Latex. Adicionalmente, este informe genera un resumen de los distintos valores, en una tabla final como la reflejada en la Figura 5.

#### V-B. Informe de ranking

A veces los valores medios interesan menos que la posición relativa de cada algoritmo. En este informe se ordena para cada función los algoritmos por su posición (1 al mejor, 2 al siguiente, y así sucesivamente), destacando el mejor, como se puede observar en la Figura 6. Además de remarcar la mejor media, incluye en la línea final el ranking medio por algoritmo, y una tabla final con los ranking medios para cada hito.

#### V-C. Informe de gráficas de convergencia

En este informe se muestra la evolución del error medio para cada función y algoritmo en cada hito. La curva puede ser más o menos suave, dependiendo del número de hitos asociados al *benchmark*. La Figura 7 muestra un ejemplo para el CEC'2013, donde sólo hay registrados tres hitos, y es más abrupta que en el caso de la Figura 8, correspondiente al CEC'2017, con más hitos y, por tanto, más suave. En la Figura 8, se muestra claramente que LSHDE\_SPACMA ofrece una mejora suave pero continua, mientras que otros algoritmos como RB-IPOP-CMA-ES convergen más rápidamente pero se estancan antes, confirmando lo indicado en la tabla de medias.

### Accuracy: 3.0e+06

Functions	CC-CMA-ES	DEEPSO	MOS	SHADEILS	VMODE
F01	5.770e-09	1.440e+08	0.000e+00	2.694e-24	8.510e-04
F02	1.330e+03	1.490e+04	8.320e+02	9.999e+02	5.510e+03
F03	1.510e-13	2.040e+01	9.170e-13	2.005e+01	3.410e-04
F04	2.190e+09	4.770e+09	1.740e+08	1.478e+08	8.480e+09
F05	7.280e+14	1.450e+07	6.940e+06	1.391e+06	7.280e+14
F06	5.870e+05	1.020e+06	1.480e+05	1.023e+06	1.990e+05
F07	7.440e+06	1.540e+07	1.620e+04	7.405e+01	3.440e+06
F08	3.880e+14	5.420e+12	8.000e+12	3.173e+11	3.260e+13
F09	3.710e+08	9.170e+08	3.830e+08	1.636e+08	7.510e+08
F10	7.550e+05	9.070e+07	9.020e+05	9.181e+07	9.910e+06
F11	1.580e+08	5.600e+08	5.220e+07	5.105e+05	1.580e+08
F12	1.270e+03	1.540e+10	2.470e+02	6.182e+01	2.340e+03
F13	6.690e+08	8.750e+08	3.400e+06	1.003e+05	2.430e+07
F14	7.100e+07	4.330e+08	2.560e+07	5.760e+06	9.350e+07
F15	3.030e+07	7.040e+06	2.350e+06	6.254e+05	1.110e+07
Best	2	0	3	11	0

Excel Latex

Figura 4: Ejemplo de informe comparativo de medias para CEC'2013.

### Bests by algorithm

	120000	600000	3000000
CC-CMA-ES	2	2	2
DEEPSO	0	0	0
MOS	6	3	3
SHADEILS	6	10	11
VMODE	1	0	0

Excel Latex

Figura 5: Ejemplo de informe comparativo final de medias para CEC'2013.

#### V-D. Informe F1 del benchmark CEC'2013

Este informe es específico para el *benchmark* CEC'2013 de alta dimensionalidad, y es un buen ejemplo de la flexibilidad del *framework*. En esta competición, se ordena a los participantes según el sistema de puntos de la F1, en el que cada corredor recibe un número de puntos según su



Accuracy: 3.0e+06

Functions	CC-CMA-ES	DEEPSO	MOS	SHADEILS	VMODE
F01	3	5	1.5	1.5	4
F02	3	5	1	2	4
F03	1	5	2	4	3
F04	3	4	2	1	5
F05	4.5	3	2	1	4.5
F06	3	4	1	5	2
F07	4	5	2	1	3
F08	5	2	3	1	4
F09	2	5	3	1	4
F10	1	4	2	5	3
F11	3.5	5	2	1	3.5
F12	3	5	2	1	4
F13	4	5	2	1	3
F14	3	5	2	1	4
F15	5	3	2	1	4
Mean	3.200	4.333	1.967	1.833	3.667

Excel    Latex

Figura 6: Ejemplo de informe comparativo de rankings para CEC'2013.

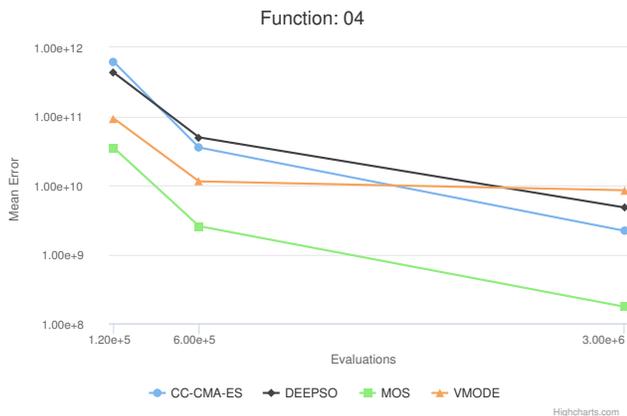


Figura 7: Ejemplo de gráfica de convergencia para la función 4 del benchmark CEC'2013

posición final: 25 puntos para el ganador, 18 para el segundo, etc. Análogamente, el informe asigna a cada algoritmo los puntos correspondientes a su posición para cada función. Los resultados son luego sumados para cada grupo de funciones (unimodales vs. multimodales, separables vs. no-separables, etc.) o globalmente. La Figura 9 muestra los datos desglosados de acuerdo a la separabilidad de las funciones, con una

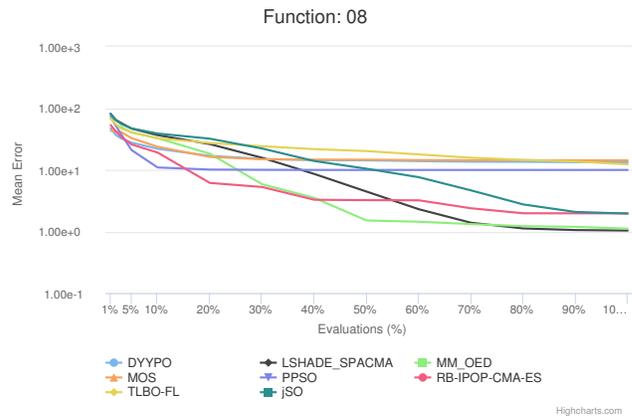


Figura 8: Ejemplo de gráfica de convergencia para la función 8 del benchmark CEC'2017

gráfica por cada hito del *benchmark*. A su vez, la Figura 10 presenta una comparativa global (sumando los puntos de cada hito). El color de cada componente de la figura representa el subgrupo de funciones, de acuerdo a las características antes mencionadas y, al pasar el ratón por cada componente, se indica el valor exacto de puntos y el nombre de esa categoría.

De ambas figuras destaca que MOS [8] obtiene los mejores resultados a partir de un número de evaluaciones, y prácticamente en todas las categorías.

V-E. Inclusión de nuevos informes

Para permitir una mayor flexibilidad, cada informe es una clase, que define un API de funciones que deben implementarse. Estas funciones devolverán, por medio de una librería, las tablas y figuras que se incorporarán al análisis. Por cada elemento (ya sea una tabla o una figura) el informe necesita devolver una estructura con la siguiente información: el objeto a devolver; el tipo del objeto (tabla o figura); y el orden del elemento, para permitir combinar tanto tablas como figuras de forma alternada dentro de un mismo informe.

Para generar las tablas, la aplicación utiliza *dataframes* de la librería *pandas*, considerada el estándar para cálculo científico. Para crear figuras, se ofrecen unas funciones propias que sirven como capa de abstracción para generar fácilmente distintos tipos de gráficas, tales como diagramas de barras, de líneas, etc. El motivo de esta abstracción es simplificar el proceso, y permitir a los informes ser independientes de las librerías de visualización que hay por debajo, para poder cambiarlas, llegado el caso, sin modificar los informes existentes.

Actualmente, se da soporte tanto a la librería *Holoviews*<sup>6</sup>, (librería de software libre para web, que presenta limitaciones de funcionalidad y es lenta), como a la librería *Highcharts*<sup>7</sup> (más rápida y con mayor funcionalidad, pero que es comercial, aunque permite el uso gratuito si se usa sin fines comerciales).

<sup>6</sup><http://holoviews.org>

<sup>7</sup><https://www.highcharts.com>

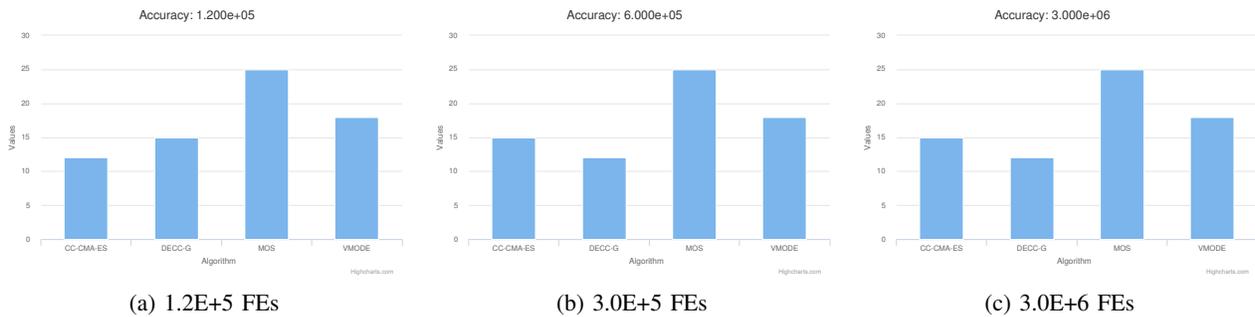


Figura 9: Resultados para el criterio de la F1 para funciones no separables.

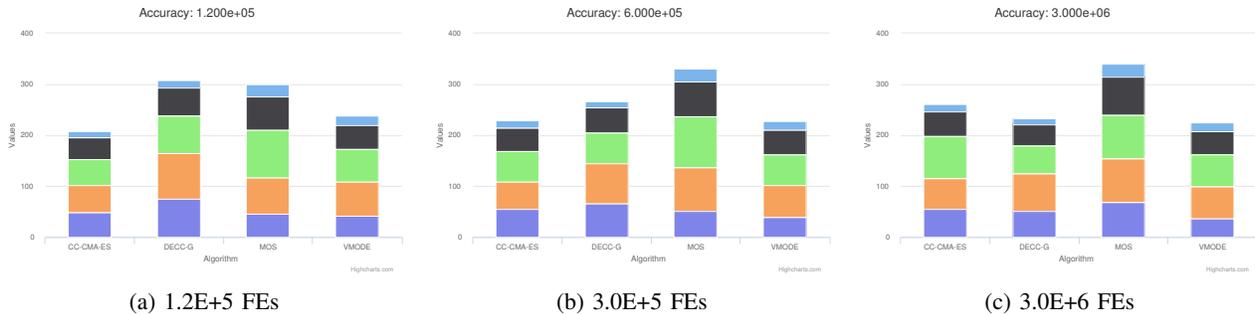


Figura 10: Resultados para el criterio de la F1 para todas las funciones.

En un futuro se plantea incorporar la librería *Altair*<sup>8</sup>, muy prometedora y que está actualmente en desarrollo.

## VI. CONCLUSIONES

En este trabajo hemos presentado TACO, Toolkit for the Automatic Comparison of Optimizers, una herramienta online avanzada para la comparación de algoritmos. Como se ha discutido, actualmente es capaz de manejar múltiples *benchmarks* y su información asociada (número de funciones, distinto número de dimensiones, hitos requeridos, grupos de funciones, etc). Además, para cada *benchmark* se pueden realizar, de forma automática, distintos tipos de análisis. La aplicación fue concebida como soporte para competiciones, pero es de utilidad para todos los investigadores que necesiten comparar sus propuestas, ya que los resultados son exportables para incluirlos en sus artículos y no requiere registro previo.

Aunque está suficientemente maduro y listo para ser usado en producción, existen planes para seguir extendiendo y mejorando TACO, que incluyen el aumento de la base de datos con más *benchmarks* y algoritmos, la inclusión de más información sobre los algoritmos, nuevos tipos de informes, especialmente con *tests estadísticos*, la exportación global de todas las tablas y figuras (actualmente, se deben exportar una a una), etc.

Como puede verse, TACO es una herramienta potente y flexible para comparar distintos algoritmos. Es más, aunque está enfocado a las metaheurísticas, puede usarse para comparar algoritmos de diferentes dominios (Machine Learning, etc.).

<sup>8</sup><https://altair-viz.github.io>

## AGRADECIMIENTOS

Este trabajo ha sido financiado, en parte, por ayudas del Ministerio de Ciencia, Innovación y Universidades (TIN2014-57481-C2-2-R, TIN2016-8113-R, TIN2017-83132-C2-2-R y TIN2017-89517-P) y de la Junta de Andalucía (P12-TIC-2958).

## REFERENCIAS

- [1] F. Glover and G. A. Kochenberger, *Handbook of metaheuristics*. Springer, 2003.
- [2] A. LaTorre, S. Muelas, and J. M. Peña, "A Comprehensive Comparison of Large Scale Global Optimizers," *Information Sciences*, vol. 316, pp. 517–549, 2015.
- [3] J. A. Parejo, A. Ruiz-Cortés, S. Lozano, and P. Fernandez, "Metaheuristic optimization frameworks: a survey and benchmarking," *Soft Computing*, vol. 16, no. 3, pp. 527–561, 2012.
- [4] N. H. Awad, M. Z. Ali, J. J. Liang, B. Y. Qu, and P. N. Suganthan, "Problem Definitions and Evaluation Criteria for the CEC 2017 Special Session and Competition on Single Objective Real-Parameter Numerical Optimization," Tech. Rep., Oct. 2016.
- [5] J. Liang, B.-Y. Qu, P. Suganthan, and A. Hernández-Díaz, "Problem definitions and evaluation criteria for the cec 2013 special session and competition on real-parameter optimization," Computational Intelligence Laboratory, Zhengzhou University, Zhengzhou China and Technical Report, Nanyang Technological University, Singapore, Tech. Rep., 2013.
- [6] R. Biedrzycki, "A version of ipop-cma-es algorithm with midpoint for cec 2017 single objective bound constrained problems," in *2017 IEEE Congress on Evolutionary Computation (CEC)*, June 2017, pp. 1489–1494.
- [7] N. Awad, M. Ali, and P. Suganthan, "Ensemble sinusoidal differential covariance matrix adaptation with euclidean neighborhood for solving cec2017 benchmark problems," in *2017 IEEE Congress on Evolutionary Computation (CEC)*, June 2017, pp. 372–379.
- [8] A. LaTorre and J. M. Peña, "A comparison of three large-scale global optimizers on the cec 2017 single objective real parameter numerical optimization benchmark," in *2017 IEEE Congress on Evolutionary Computation (CEC)*, June 2017, pp. 1063–1070.



# Creating Difficult Instances of the Linear Ordering Problem

Aritz Pérez\* and Josu Ceberio†

\*Basque Center for Applied Mathematics (BCAM), 48009 Bilbao, Spain

†Faculty of Computer Science, 20018 Donostia, Spain

University of the Basque Country UPV/EHU

email: aperez@bcamath.org, josu.ceberio@ehu.eus

**Abstract**—Generating random instances of a given problem is a task that is addressed very frequently in combinatorial optimization. Some times this task is motivated by the lack of challenging instances, some other times practitioners have few instances and need to generate large benchmarks to evaluate their algorithms. Be that as it may, creating instances that are challenging enough for the algorithm at hand is not trivial, and implies other considerations such as defining the concept of difficulty.

In this paper, we address the problem of randomly generating difficult instances of the linear ordering problem for local search algorithms. Based on the joint analysis of the problem and a neighborhood structure, we conclude that one way to create difficult instances is to organize its parameters in the way that the variance of the fitness in the neighborhood is very low. To this end, we propose a simple procedure that generates the parameters matrix in such a way that for any row and column, the sum of the parameters is constant. The experimental study shows that the proposed method generates instances of higher difficulty than the standard method, setting the parameters independently and identically distributed according to a uniform distribution.

## I. INTRODUCTION

In the field of evolutionary computation, it is common to use benchmarks of instances of a given problem in order to evaluate the performance of existing and newly developed algorithms. When the final goal is to solve a specific real-world problem, real instances are used to carry out such comparisons, and, thus, we are not interested in an extensive performance evaluation. However, when the objective of the research is to contribute with methodological developments, then large benchmarks of instances are needed in order to analyze the behavior of the proposed algorithm under different scenarios. In this sense, real-world benchmarks are usually limited in size and variety of instances.

At this point, it is a usual practice, based on the knowledge of the problem (limited in most cases), to create new “challenging” instances artificially [1], [2], [3], [4], [5]. In this sense, a recurrent option is to generate instances by sampling their parameters uniformly at random (u.a.r) in some ranges. The underlying assumption states that sampling u.a.r in the space of parameters is equivalent to sampling u.a.r in the space of instances and, thus, uniform in terms of difficulty. Nonetheless, recent works on this line [6], [7] have shown that such statement is not necessarily true.

In [6], the authors focused on the random generation of artificial instances of combinatorial optimization problems. Particularly, they stated that most of the algorithms take only into account the ordering of the solutions (better, worse...) during the optimization and, therefore, any instance can be seen as a ranking of all the solutions in the search space. In this context, the authors discovered that there exist classes of equivalence of the mentioned rankings according to their difficulty (in terms of number of local optima). Not limited to that, conducted experiments demonstrated that when sampling independently and identically distributed (i.i.d.) parameters according to a uniform distribution, the majority of the instances induce rankings that belong to “easy” classes of equivalence (have one or two local optima).

On that research line, in [7] the authors tried to go deeper in the difficulty of instances for best improvement local search algorithms when sampling the parameters u.a.r. Despite their simplicity, local search algorithms permit easily tracking the optimization process and, thus, it is possible to carry out an exact study of the difficulty of the instance on the basis of fitness landscape analysis [8]. The work in [7] focused on three problems and four neighborhood structures, and tried to answer the following question: *are the artificially generated instances uniform in terms of difficulty?* The experimental study revealed that (1) by sampling the parameters uniformly at random the obtained instances are non-uniform in terms of difficulty, (2) the distribution of the difficulty strongly depends on the pair problem-neighborhood considered, and (3) given a problem, the distribution of the difficulty seems to depend on the landscape induced by the neighborhood structure and its size.

However, what creates the difficulty for a specific algorithm in each problem is unique and it is not clear. In this work, we take as case of study the *Linear Ordering Problem* (LOP) [9], [10] and *best improvement local search algorithm* (BI) under the insert neighborhood. In that context, we approach the problem of creating difficult instances.

Firstly, we defined the difficulty of an instance as 1 minus the probability of reaching the global optimum solution after performing a BI starting from a random solution. Secondly, based on the joint study of the LOP and insert neighborhood, we considered that one way to create difficult artificial instances can be to sample a set of parameters that induces low

fitness variations in the neighborhood of a solution.

On that line, we propose a procedure for generating artificial instances by defining a parameters matrix of the instance in which every row and column sum a constant value. This type of parameters matrix tends to induce low fitness differences of the solutions in the insert neighborhoods.

In the experimental section, we generate thousands of instances of the LOP for different sizes of the problem. The instances have been generated by using i) the classical uniform procedure, and ii) the proposed procedure. Then, we estimate the difficulty of each instance generated for BI under the insert neighborhood and we analyze the evolution of the difficulty of the generated instances with respect to the size of the problem,  $n$ . The results point out that the proposed procedure obtain more difficult instances than the classical option.

The remainder of the paper is organized as follows: in Section II the necessary background on combinatorial optimization, LOP, local search and difficulty is introduced. In Section III, the main contribution of the paper, a method to create difficult instances of the LOP for BI is proposed. Afterwards, the experimental study is presented in Section IV. Finally, conclusions and research lines for future work are summarized in Section V.

## II. BACKGROUND

A combinatorial optimization problem (COP), denoted as  $\mathbf{P} = (\Omega, f)$ , consists of a finite (or infinite countable) domain of solutions  $\Omega$ , also known as search space, and an *objective function*  $f$  which is formalized as

$$f : \Omega \rightarrow \mathbb{R} \\ x \mapsto f(x)$$

We call to the value  $f(x)$  the *fitness* of  $x$ . The definition of a problem includes certain inputs that are known as *parameters*. The collection of parameters that describe a particular case of the problem is called the *instance*.

The aim in a COP is to, given an instance, find  $x \in \Omega$  such that  $f$  is maximized (or minimized). As the computation of  $f(x)$  is closely tied to the instance, in the remainder of the paper, we say that  $f$  is an instance or an objective function indistinctly. The LOP is an example of a COP. In the following, a brief introduction to it is presented.

### A. The Linear Ordering Problem

Given a matrix  $B = [b_{i,j}]_{n \times n}$  of numerical entries, the LOP [9], [10] consists of finding a simultaneous permutation  $\sigma$  of the rows and columns of  $B$ , such that the sum of the entries above the main diagonal is maximized (or equivalently, the sum of the entries below the main diagonal is minimized). The equation below formalizes the objective function:

$$f(\sigma) = \sum_{i=1}^{n-1} \sum_{j=i+1}^n b_{\sigma_i, \sigma_j} \quad (1)$$

where  $\sigma_i$  denotes the index of the row (and column) ranked at position  $i$  in the solution  $\sigma$ . The numerical entries  $b_{i,j}$

for  $i, j = 1, \dots, n$  are the parameters of the problem and, generally,  $b_{i,i} = 0$  for  $i = 1, \dots, n$ . A particular assignment of values to these parameters constitutes an instance. Fig. 1 introduces an illustrative example of an LOP instance in its *triangulation* form. Gray background parameters are the only

	1	2	3	4	5
1	0	16	11	15	7
2	21	0	14	15	9
3	26	23	0	26	12
4	22	22	11	0	13
5	30	28	25	24	0

Fig. 1: LOP instance of size  $n = 5$ .

ones considered in the computation of the fitness function. The search space of solutions  $\Omega$  consist of all permutations of size  $n$ , so its size is  $|\Omega| = n!$ .

### B. Local search on the LOP

Local Search algorithms (LS) optimize based on a neighborhood system, a function that relates a set of solutions to each solution  $x \in \Omega$ . Formally a *neighborhood* is defined as

$$N : \Omega \rightarrow 2^{|\Omega|} \\ x \mapsto N(x)$$

where  $2^{|\Omega|}$  represents the power set of the domain  $\Omega$ .

LS is a sequential optimization heuristic that progresses by moving from a solution to a neighboring solution. Consequently, the behavior of a particular LS is determined by the neighborhood defined, and the criteria used to select a solution from the neighborhood. Two of the most used strategies are the *best improvement* (BI) and the first improvement selection criteria. BI progresses by selecting, among the neighboring solutions the solution with the best fitness, while the first improvement progresses by selecting a neighboring solution with a better  $f(\sigma)$  value. Both algorithms are said to converge to a (local) optimum solution when all the neighboring solutions have equal or worse  $f(\sigma)$  value.

In local search optimization, a wide range of neighborhood structures have been proposed in order to deal with combinatorial problems. Depending on the characteristics of the problem, some neighborhoods show better performance than others [11]. According to [7], the insert neighborhood is the structure that most favorable landscapes generates for the LOP. From our perspective, this is probably motivated by its considerable size and the few number of parameters exchanged between neighboring solutions.

Let us now consider a permutation  $\sigma$  of size  $n$ . The insert neighborhood considers as neighbors all the solutions that can be obtained by moving any item from a position  $i$  to any position  $j$ . The items between positions  $i$  and  $j$  are shifted. As a result, the size of the neighborhood is  $(n - 1)^2$ .



Fig. 2 presents an example of an LOP instance for two different solutions:  $e$  and  $\sigma$ . The second solution is obtained by performing an insert movement of item 2 to position 3. In both cases, the pairs of parameters associated to item 2 are circled. As can be seen in the figure, due to the insert

	1	2	3	4	5
1	0	16	11	15	7
2	21	0	14	15	9
3	26	23	0	26	12
4	22	22	11	0	13
5	30	28	25	24	0

	1	3	2	4	5
1	0	11	16	15	7
3	26	0	23	26	12
2	21	14	0	15	9
4	22	11	22	0	13
5	30	25	28	24	0

(a)  $e = (1, 2, 3, 4, 5)$ ,  $f(e) = 138$ .      (b)  $\sigma = (1, 3, 2, 4, 5)$ ,  $f(\sigma) = 147$ .

Fig. 2: Two different solutions for an instance of  $n = 5$ . Circled values denote the parameters associated to item 2.

movement, a pair of parameters,  $(14, 23)$  is swapped from side, and thus,  $f(\sigma)$  increases from 138 to 147. Note that the rest of the parameters, despite they are reallocated, they remain in the same side with respect to the main diagonal. In general, if we insert the  $i$ -th element in the  $j$ -th position we swap  $|i - j|$  parameters [7]. The general effect of an insert operation is illustrated in Figure 3.

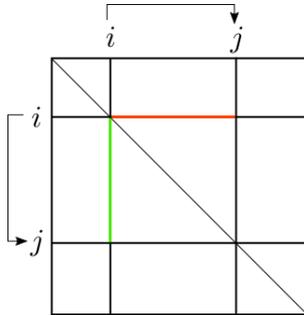


Fig. 3: The parameters swapped by insert  $i$ -th element in position  $j$ . Green lines and red lines represent the parameters that are added and subtracted to the objective function, respectively

### C. Measuring the Difficulty

As proposed in [7], we consider the difficulty of an instance of the LOP as 1 minus the probability of reaching the global optimum solution by using BI and by picking a solution of  $\Omega$  at random. In other words, the difficulty is 1 minus the size of the basin of attraction of the global optimum divided by the size of the search space,  $n!$ . In this work, we estimate the difficulty of an instance by running 100 times BI initialized with a random solution. The difficulty is estimated as 1 minus the percentage that BI have reached the global optimum.

It is our intuition that if exists a solution in the neighborhood whose fitness is quantitatively larger than the rest, then

decision to move to this solution by the BI tends to increase the chance to reach to the global optimum. In this scenario, we say that the decision is supported with strong evidence and the neighborhood becomes more informative. In this sense, in the next section, we propose a method to generate artificial instances in which the solutions in the neighborhood have small differences in the fitness.

### III. CREATING DIFFICULT INSTANCES OF THE LOP

Usually, in the literature, in order to generate artificial instances of LOP the parameters are sampled according to a uniform distribution [7]. Using this procedure it is possible to generate an instance  $B$  with unbalanced sums by rows and by columns which can be easily exploited by heuristic optimization algorithms, such as BI under the insert neighborhood. Nonetheless, if we generate instances in which the independent sum of rows and columns are equally weighted, then the insert neighborhood tends to provide similar fitness variations in the neighborhood of a solution, and it becomes less informative (see Figure 3).

In this work, with the aim of generating more difficult instances than the uniform approach, we propose a method that produces a matrix  $B$  for which the sum of each row and each column sum 1. Specifically, the scheme proceeds as follows. First, two matrices  $R$  and  $C$  are created. In  $R$ , the rows of parameters are obtained by sampling a Dirichlet distribution. Similarly, in  $C$ , the sampled vectors correspond to columns in the matrix. Next, once  $R$  and  $C$  are obtained, the randomly generated instance is given as  $B = 1/2 \cdot (R + C)$ . Finally, following the next iterative normalization procedure we obtain a matrix  $B$  for which any row or column sum one. The procedure works as follows, first, the parameters of every row are normalized independently in order to sum 1. Next, the same normalization process is applied to the columns. Both steps are subsequently repeated until result converges to the matrix with the characteristics above.

Note that in LOP,  $b_{i,i} = 0$  for  $i = 1, \dots, n$ . Thus the diagonal of  $R$  and  $C$  have to be zero and, thus, we sample a Dirichlet distribution with  $n - 1$  parameters for each row and column of  $R$  and  $C$ , respectively. In this work, the parameters are equal to one, that is  $\alpha = \alpha_i = 1$  for  $i = 1, \dots, n - 1$ .

### IV. EXPERIMENTAL STUDY

In this section, we artificially generate LOP instances following two different schemes, and, we analyze the generated instances in terms of the distribution of the difficulty.

For this purpose, we have artificially generated  $10^4$  instances of the LOP for each problem size  $n = 8, \dots, 20$ . The parameters of the instances have been sampled by using i) the classic uniform procedure in the  $[0, 1]$  interval and ii) the proposed Dirichlet procedure with  $\alpha = 1$ . Next, we have obtained the global optimum of each instance by solving it using the branch and bound algorithm proposed by Charon et al. [12]. Finally, for each instance generated we have run a BI under the insert neighborhood 100 times, and estimated its

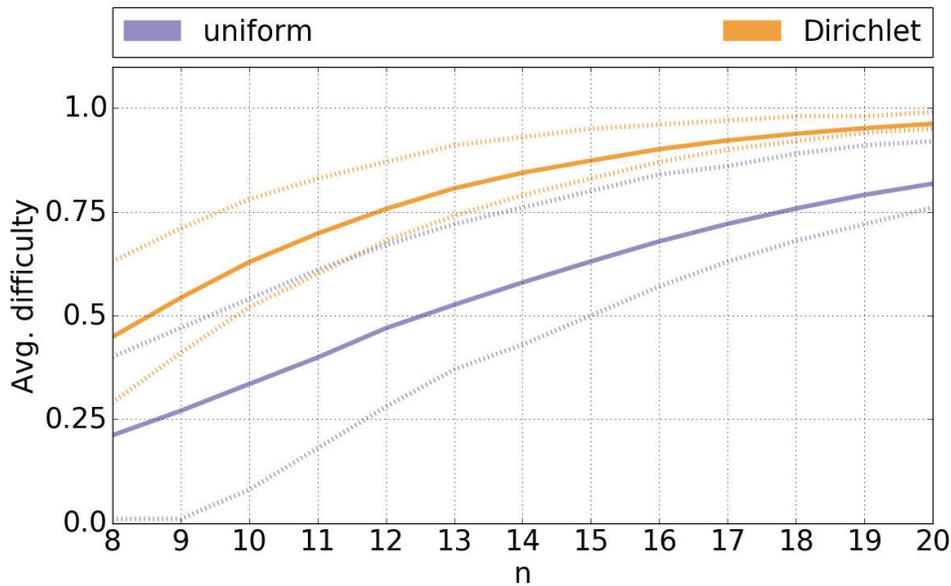


Fig. 4: The evolution of the average difficulty (together with the first and third quartiles) for the uniform and the Dirichlet with respect to the size of the problem  $n = 6, \dots, 20$ .

difficulty by counting the percentage of times it reaches the global optimum.

We have analyzed the evolution of the distribution of the difficulty with respect to the size of the LOP,  $n$ . The results are summarized in Figs. 4 and 5. The first illustrates the evolution of the average difficulty (and the first and third quartiles) for the compared schemes for the different  $n$  values. Figure 5 provides a more detailed view of the results showing the distribution of the difficulty.

Results reveal that, as  $n$  increases, instances tend to be more difficult using both procedures. In addition, we see that the instances generated by the Dirichlet procedure are more difficult. The dispersion of the generated difficulties using the Dirichlet procedure is smaller than the obtained by the uniform procedure, especially for the largest instances. Moreover, as  $n$  increases the third quartile of the difficulty for the Dirichlet procedure is higher than the first quartile of the uniform procedure.

## V. CONCLUSION & FUTURE WORK

In this work, we have addressed the problem of generating difficult instances of the linear ordering problem for the best improvement local search under the insert neighborhood. Based on the joint analysis of the LOP instances and the insert neighborhood structure, we concluded that a possible manner is to organize its parameters in such a way that the variance of the fitness in the neighborhood is very low. To this end, we propose a procedure for generating artificial instances as a matrix of parameters in which the sum of each row and each column is constant. Conducted experiments show that the proposed method tends to generate instances of higher difficulty than other standard methods such as setting the parameters i.i.d. according to a uniform distribution.

However, there are a number of questions still pending. For instance, results in Fig. 5 show small peaks in the distribution of the difficulty, that are consistently repeated for the two instance generation methods across the different  $n$  values. The answer should be in the definition of the problem and the structure of the neighborhood.

In addition, we aim to study the effect of the  $\alpha$  parameters of the Dirichlet procedure in the distribution of the difficulty. It is our intuition that  $\alpha$  parameter could be used in order to further increase the difficulty of the generated instances.

Finally, we find interesting to extend this work to other problem-neighborhood pairs. For instance, for the pair Quadratic Assignment Problem (QAP) and interchange neighborhood [11], [13], it is very probable that the same principle of low variance fitness neighbors will produce difficult instances. Nevertheless, the manner in which the instances are generated for QAP is apparently much more complex as it doubles the number of parameters of the LOP. Not limiting to the domain of local search algorithms, it is possible to extend the work to other algorithms, as the principle of low variance fitness instances may produce difficult scenarios for population-based algorithms as well.

## ACKNOWLEDGMENT

This work has been partially supported by the Research Groups 2013-2018 (IT-609-13), BERC 2014-2017, and ELKARTEK programs (Basque Government), the projects TIN2016-78365-R and TIN2017-82626-R (Spanish Ministry of Economy, Industry and Competitiveness) and Severo Ochoa Program SEV-2013-0323 (Spanish Ministry of Economy, Industry and Competitiveness).

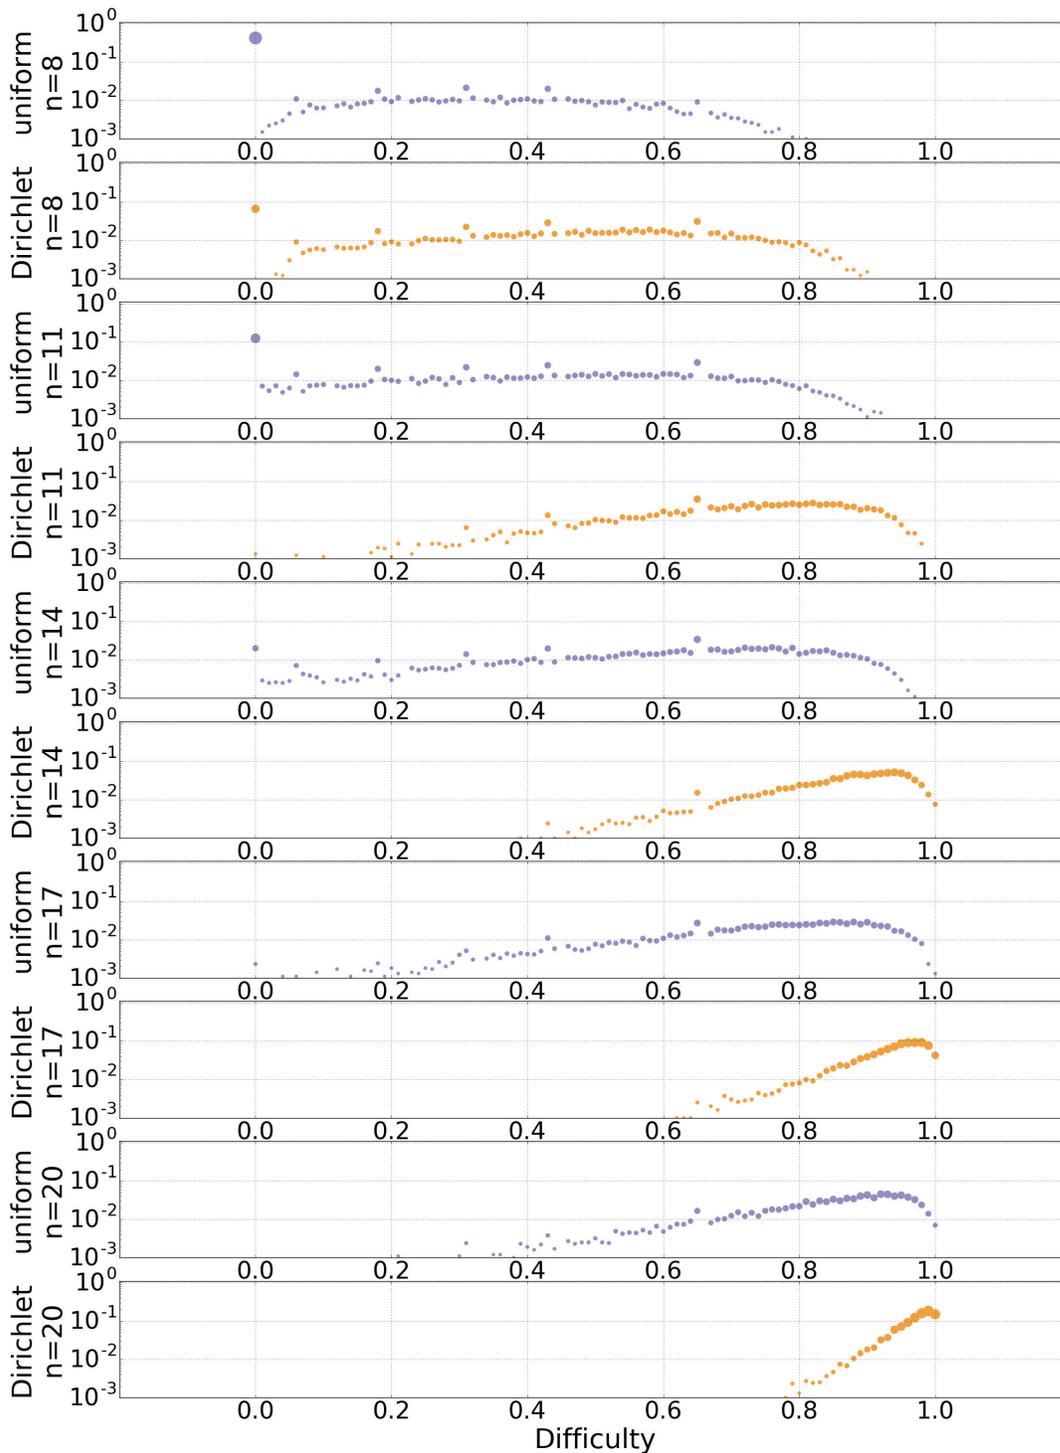


Fig. 5: The distribution of the difficulty of the instances generated by using the uniform and Dirichlet procedures for different problem sizes,  $n = 8, 11, 14, 17, 20$ . The  $x$  axis is the difficulty and the  $y$  axis the frequency in which instances of a given difficulty are generated. Each point corresponds to a difficulty and its area is proportional to the number of instances generated with this difficulty.

## REFERENCES

- [1] I. P. Gent and T. Walsh, "The TSP phase transition," *Artificial Intelligence*, vol. 88, no. 1–2, pp. 349 – 358, 1996.
- [2] E. Taillard, "Benchmarks for basic scheduling problems," *European Journal of Operational Research*, vol. 64, no. 2, 1993.
- [3] Z. Drezner, P. Hahn, and É. Taillard, "Recent advances for the quadratic assignment problem with special emphasis on instances that are difficult for meta-heuristic methods," *Annals of Operations Research*, vol. 139, no. 1, pp. 65–94, 2005.
- [4] T. Schiavinotto and T. Stützle, "The linear ordering problem: Instances, search space analysis and algorithms," *Journal of Mathematical Modelling and Algorithms*, vol. 3, no. 4, pp. 367–402, 2005.
- [5] A. Duarte, M. Laguna, and R. Martí, "Tabu search for the linear ordering problem with cumulative costs," *Computational Optimization and Applications*, vol. 48, no. 3, pp. 697–715, 2011.
- [6] J. Ceberio, A. Mendiburu, and J. A. Lozano, "Are we generating instances uniformly at random?" in *2017 IEEE Congress on Evolutionary Computation (CEC)*. IEEE, 2017, pp. 1645–1651.
- [7] A. Perez, J. Ceberio, , and J. A. Lozano, "Are the artificially generated instances uniform in terms of difficulty?" in *2018 IEEE Congress on Evolutionary Computation (CEC)*. IEEE, 2018.
- [8] M. Tayarani-N. and A. Prgel-Bennett, "On the landscape of combinatorial optimization problems," *IEEE Transactions on Evolutionary Computation*, vol. 18, no. 3, pp. 420–434, June 2014.
- [9] R. Martí and G. Reinelt, *The linear ordering problem: exact and heuristic methods in combinatorial optimization*. Springer, 2011, vol. 175.
- [10] J. Ceberio, A. Mendiburu, and J. A. Lozano, "The Linear Ordering Problem Revisited," *European Journal of Operational Research*, vol. 241, no. 3, pp. 686–696, 2014.
- [11] J. Ceberio, E. Irurozki, A. Mendiburu, and J. A. Lozano, "A review of distances for the mallows and generalized mallows estimation of distribution algorithms," *Computational Optimization and Applications*, vol. 62, no. 2, pp. 545–564, 2015.
- [12] I. Charon and O. Hudry, "A branch-and-bound algorithm to solve the linear ordering problem for weighted tournaments," *Discrete Applied Mathematics*, vol. 154, no. 15, pp. 2097 – 2116, 2006.
- [13] J. Ceberio, A. Mendiburu, and J. A. Lozano, "Kernels of mallows models for solving permutation-based problems," in *Proceedings of the 2015 Annual Conference on Genetic and Evolutionary Computation*, ser. GECCO '15. ACM, 2015, pp. 505–512.



# Anatomy of the Attraction Basins: Breaking with the Intuition

Leticia Hernando\*, Alexander Mendiburu†, Jose A. Lozano\*‡

\*Intelligent Systems Group, Department of Computer Science and Artificial Intelligence  
University of the Basque Country UPV/EHU, 20018 San Sebastián, Spain  
leticia.hernando@ehu.eus

†Intelligent Systems Group, Department of Computer Architecture and Technology  
University of the Basque Country UPV/EHU, 20018 San Sebastián, Spain  
alexander.mendiburu@ehu.eus

‡Basque Center for Applied Mathematics (BCAM)  
48009 Bilbao, Spain  
ja.lozano@ehu.eus

**Abstract**—This is a summary of the motivations, contributions, experiments and conclusions of the article titled *Anatomy of the Attraction Basins: Breaking with the Intuition* that has been accepted for publication in *Evolutionary Computation journal* (doi: 10.1162/EVCO\_a\_00227) [1].

## I. INTRODUCTION

Solving combinatorial optimization problems efficiently requires the development of algorithms that consider the specific properties of the problems. In this sense, local search algorithms are designed over a neighborhood structure that partially accounts for these properties. Considering a neighborhood, the space is usually interpreted as a natural landscape, with valleys and mountains. Under this perception, it is commonly believed that, if maximizing, the solutions located in the slopes of the same mountain belong to the same attraction basin, with the peaks of the mountains being the local optima. Unfortunately, this is a widespread erroneous visualization of a combinatorial landscape. Thus, our aim is to clarify this aspect, providing a detailed analysis of, first, the existence of plateaus where the local optima are involved, and second, the properties that define the topology of the attraction basins, picturing a reliable visualization of the landscapes. Some of the features explored in this paper have never been examined before. Hence, new findings about the structure of the attraction basins are shown. The study is focused on instances of permutation-based combinatorial optimization problems considering the 2-exchange and the insert neighborhoods. Particularly, we work with the permutation flowshop scheduling problem (PFSP), the linear ordering problem (LOP) and the quadratic assignment problem (QAP). As a consequence of this work, we break away from the extended belief about the anatomy of attraction basins.

## II. ANALYSIS OF THE TOPOLOGY OF THE ATTRACTION BASINS

### A. Local optima and local optimal plateaus

A best-improvement local search algorithm returns a local optimum that necessarily match one, and only one, of the three

following options: (i) be a strict local optimum, (ii) belong to a local optimal plateau, or (iii) belong to an open plateau. Thus, we show the number of strict local optima, the number of local optimal plateaus and the number of open plateaus that appear in the instances chosen for the analysis. In general, for the three analyzed problems, the presence of plateaus is remarkable. One of the main conclusions derived from this study is that, usually, the algorithm gets trapped inside the plateaus. That is, although we find instances with plateaus composed by just two solutions, this algorithm is not designed to detect and escape from them.

### B. Roundness of the attraction basins

An attraction basin is considered to be round if all the solutions at distance 1, 2, ... until a certain distance  $r$  from the local optimum or the plateau are within the attraction basin. We record, for the smaller instances, for each local optimum, the proportion of solutions belonging to its attraction basin that are at different distances from it. On average, the local optima are located in the frontier of the attraction basins, as they have a number of neighboring solutions belonging to a different attraction basin. However, on average, we also find solutions at the longest distances from them that do belong to their attraction basins. This structure clearly differs from the concept of roundness.

### C. Centrality of the local optima

We aim to study the position of the local optima within the attraction basins. We focus on the centrality of the local optima inside the attraction basins. The local optima (or the plateaus) are considered to be centered if they minimize the average distance to the rest of the solutions in the attraction basin. We observe that, in general, the local optima of the instances have a lower average distance than the rest of the solutions of the attraction basins. We conclude that the local optima are located close to the barycenter of the attraction basins, as they have the minimal (or almost the minimal) average distances to

the rest of the solutions: in general, they are almost centered within the attraction basins.

#### D. Interior and frontier of the attraction basins

There is a really low number of solutions in the interior of the attraction basins. Surprisingly, the average number of neighboring attraction basins is really high (close to the total number of local optima). Basically, almost all of the attraction basins are neighboring attraction basins. Moreover, those solutions that are close to the local optimum have a large proportion of their neighbors inside the same attraction basin. The solutions that are far from the local optimum have a small number of neighbors in the same attraction basin, while the number of different neighboring attraction basins is large. If we take all the solutions of an attraction basin, the connectivities with other different attraction basins are higher for those solutions at long distances from the local optima.

The attraction basins are intertwined in the search space: the paths drawn by the local search algorithm are interconnected with each other or, at least, they are close to each other.

### III. VISUALIZATION OF THE ATTRACTION BASINS

We give a representation of a specific attraction basin by means of a network showing all the paths encountered until the local optimum is reached. Each node of the graph represents one solution belonging to the attraction basin. Edges between nodes indicate that the node at the end of the edge is the best neighbor of the node at the start of the edge. The color of the nodes changes with the distance to the local optimum. Particularly, red, yellow, green, light blue, dark blue and purple are used to represent the solutions at distances 0 (the local optima), 1, 2, 3, 4 and 5, respectively. The size of the nodes and the width of the edges also decrease as the distance to the local optimum increases.

Figure 1 presents two different graphs illustrating the same attraction basin of a local optimal plateau of a PFSP instance when using the 2-exchange neighborhood. Figure 1(a) represents this attraction basin considering the steps that the algorithm takes until it reaches the local optimal plateau (and not the distances between the solutions). In an attempt to visualize this attraction basin in a more realistic way, we force the graph to take into account the distances between all the solutions that belong to the attraction basin (Figure 1(b)). The real structure of the attraction basins is more complex than one could try to imagine. More visualizations can be found at the website: <http://www.sc.ehu.es/ccwbayes/members/leticia/AnatomyOfAB/visualization/visualizeOneAB.html>.

### IV. CONCLUSION

The attraction basins can be understood as long intertwined rivers, that flow into the different local optima, instead of being mountains in a landscape. In fact, each attraction basin is composed of several of those rivers ending at the same local optimum, while at the same time, each of them could have different tributaries. Moreover, the end of those rivers can be made up of more than one local optimum that have

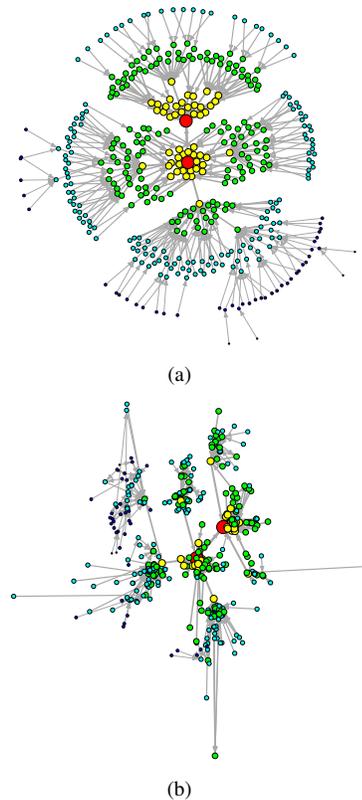


Fig. 1. Visualization of an attraction basin of a local optimal plateau found an instance of the PFSP with the 2-exchange neighborhood, considering only the steps of the algorithm (a) and taking into account, as far as possible, the distances between all the solutions (b).

the same objective function value, forming a plateau. The local optima or the plateaus composed by local optima are centered in the attraction basin. Nevertheless, we should be cautious with this perception, because by understanding the combinatorial optimization landscapes as if we were in a 3D natural landscape, we could be misunderstanding the real anatomy. The understanding of the landscapes in combinatorial optimization has been one of the main challenges when developing and improving algorithms. This work not only breaks with an erroneous extended belief about the attraction basin shapes, but also provides valuable information for the design of new algorithms based on local search.

#### ACKNOWLEDGMENT

This work has been partially supported by the Research Groups 2013-2018 (IT-609-13) programs (Basque Government) and TIN2016-78365R (Spanish Ministry of Economy, Industry and Competitiveness). Jose A. Lozano is also supported by BERC 2014-2017 and Elkartek programs (Basque government) and Severo Ochoa Program SEV-2013-0323 (Spanish Ministry of Economy and Competitiveness).

#### REFERENCES

- [1] L. Hernando, A. Mendiburu and J.A. Lozano. Anatomy of the Attraction Basins: Breaking with the Intuition. *Evolutionary Computation*, 1-32. 2018. In Press.



# SHADE con Búsqueda Local Iterativa para Optimización Global de Alta Dimensionalidad

1º Daniel Molina

*DaSCI Instituto Andaluz en Data Science  
and Computational Intelligence  
Universidad de Granada  
Granada, España  
dmolina@decsai.ugr.es*

2º Antonio LaTorre

*DATSI, ETSIINF  
Centro de Simulación Computacional  
Universidad Politécnica de Madrid  
Madrid, España  
atorre@fi.upm.es*

3º Francisco Herrera

*DaSCI Instituto Andaluz en Data Science  
and Computational Intelligence  
Universidad de Granada  
Granada, España  
herrera@decsai.ugr.es*

**Resumen**—La optimización global es un campo de investigación de gran interés dado el gran número de problemas de la ciencia y la ingeniería que pueden formularse en dichos términos. Uno de los grandes retos en este tipo de problemas es el incremento de la dimensionalidad, ya que supone un aumento en la complejidad de los mismos. Este hecho hace de la optimización global de alta dimensionalidad un campo especialmente atractivo en nuestros días. En esta contribución proponemos un nuevo algoritmo híbrido especialmente diseñado para tratar con este tipo de problemas. La propuesta combina, de manera iterativa, una reciente variante del algoritmo de Evolución Diferencial con una búsqueda local que se escoge de entre varias estrategias disponibles. Dicha selección es dinámica y se lleva a cabo teniendo en cuenta la contribución de cada una de ellas en las anteriores fases de intensificación, de tal modo que se use la más apropiada en cada una de las fases de búsqueda del algoritmo. La experimentación se ha llevado a cabo usando el benchmark de alta dimensionalidad del CEC'2013 y los resultados demuestran que la sinergia existente entre las distintas componentes del algoritmo permite obtener unos resultados que mejoran los del actual ganador de las últimas competiciones de optimización global de alta dimensionalidad, *Multiple Offspring Sampling*, MOS, con mejoras especialmente reseñables en los problemas de mayor complejidad.

**Index Terms**—Optimización Global de Alta Dimensionalidad, Evolución Diferencial, Computación Memética, Hibridación.

## I. INTRODUCCIÓN

La optimización continua es un campo de investigación muy relevante ya que muchos problemas de diversas áreas de conocimiento pueden formularse en estos términos. En este tipo de problemas, la solución puede modelarse como un vector de una determinada longitud de variables continuas en un dominio de búsqueda. Los Algoritmos Evolutivos, AEs, tales como la Evolución Diferencial, ED [1], [2], son muy útiles en la resolución de este tipo de problemas, ya que son capaces de encontrar soluciones precisas a problemas complejos sin ninguna información acerca de estos, lo cual es de gran utilidad en problemas reales [3]. Sin embargo, este tipo de algoritmos suele ser muy sensible al tamaño del problema, dado que el dominio de búsqueda aumenta exponencialmente con el número de dimensiones.

La Optimización Global de Alta Dimensionalidad, LSGO por sus siglas en inglés, es una variante concreta de este tipo de problemas en la que el tamaño del mismo suele

estar por encima del millar de variables. En este contexto, la eficiencia de las técnicas de búsqueda es crucial, debido al enorme espacio de búsqueda que debe cubrirse. En los últimos años, se han organizado varias sesiones especiales en LSGO donde se han propuesto varios algoritmos específicamente diseñados para este tipo de problemas. Una de las estrategias que está recibiendo más atención consiste en particionar el problema en subproblemas de menor tamaño. Un ejemplo de esto son las diferentes estrategias de agrupamiento de variables propuestas por algunos autores [4], [5]. No obstante, la actual referencia, y ganador de las competiciones de alta dimensionalidad desde 2013, *Multiple Offspring Sampling*, MOS [6], [7], sigue una aproximación diferente: combina dinámicamente múltiples técnicas de búsqueda que se usan de manera simultánea y cuya participación en el proceso de búsqueda se ajusta de acuerdo a su rendimiento.

En esta contribución proponemos un nuevo algoritmo, SHADE con una búsqueda local iterativa, SHADE-ILS, que combina la capacidad exploratoria de una reciente variante de la ED con la potencia de intensificación de varias Búsquedas Locales, BL. En cada iteración del algoritmo, la ED se aplica para evolucionar la población de soluciones candidatas y la BL se usa para mejorar la mejor solución encontrada hasta ese momento. Las técnicas de BL se seleccionan en cada iteración de acuerdo al rendimiento relativo obtenido previamente.

Este algoritmo se basa en el que se propuso en [8], IHDELS, pero con un importante número de diferencias: la selección de la BL a aplicar en cada generación se ha mejorado. Además, se ha introducido un mecanismo de reinicio capaz de detectar el estancamiento. Por último, en esta propuesta se ha reemplazado la ED utilizada anteriormente, SaDE [9], por otra más potente, Success-History based Adaptive DE, SHADE [10].

Los resultados de este nuevo método se han comparado con los de IHDELS, mejorando los que éste obtenía. Además, SHADE-ILS mejora los resultados del ganador de las anteriores competiciones de alta dimensionalidad, MOS [6], [7] que, no había sido mejorado desde su publicación, lo cual lo convertía en el actual *estado del arte*. De esta manera, el algoritmo propuesto, SHADE-ILS, puede ser considerado el nuevo *estado del arte* en optimización continua.

El resto del documento está organizado del siguiente modo: en la sección II, el algoritmo SHADE-ILS se describe en detalle, resaltando las principales diferencias con respecto a IHDELS. En la sección III, analizamos los resultados obtenidos por nuestro algoritmo y los comparamos con los de MOS. Por último, la sección IV presenta las principales conclusiones y líneas futuras del trabajo.

## II. PROPUESTA

En esta sección vamos a describir en detalle el algoritmo propuesto, SHADE-ILS, resaltando los cambios realizados con respecto a IHDELS. Una descripción detallada de este último puede ser consultada en [8].

---

### Algoritmo 1 SHADE-ILS

---

```
1:  $population \leftarrow random(dim, popsize)$ 
2:  $solucion\_inicial \leftarrow (upper + lower)/2$ 
3:  $actual\_mejor \leftarrow BL(solucion\_inicial)$ 
4:  $mejor\_solucion \leftarrow actual\_mejor$ 
5: while  $totalevals < maxevals$  do
6:    $previo \leftarrow actual\_mejor.fitness$ 
7:    $actual\_mejor \leftarrow SHADE(population, actual\_mejor)$ 
8:    $improvement \leftarrow previo - actual\_mejor.fitness.$ 
9:   Escoge el método de BL a aplicar en esta iteración.
10:   $actual\_mejor \leftarrow BL(population, actual\_mejor)$ 
11:  Actualiza probabilidad de aplicar BL.
12:  if  $mejor(actual\_mejor, mejor\_solucion)$  then
13:     $actual\_mejor \leftarrow mejor\_solucion.$ 
14:  end if
15:  if Debe reiniciar then
16:    Reinicia y actualiza  $actual\_mejor.$ 
17:  end if
18: end while
```

---

El algoritmo 1 muestra el esquema general de la propuesta. Como se puede observar, el algoritmo aplica, iterativamente, los métodos de ED y BL, explorando todas las variables al mismo tiempo (una diferencia importante con respecto a otros algoritmos que agrupan variables). Otra característica relevante es que el algoritmo mantiene la misma población entre fases de aplicación de la ED. Además, los parámetros del método de BL también son persistentes entre llamadas sucesivas sobre la misma solución (exceptuando tras los reinicios). Por lo tanto, el flujo del algoritmo podría resumirse en dos pasos:

- Inicialmente, se usa una técnica exploratoria para explorar el espacio de búsqueda. En nuestro caso, hemos seleccionado SHADE [10] por su simplicidad y porque auto-ajusta sus parámetros. Existe una versión que reduce el tamaño de la población, L-SHADE [11], muy popular en el campo de la optimización continua. Sin embargo, en este caso, el ajuste del tamaño de la población reduciría demasiado rápidamente sus capacidades de exploración.
- Al final de cada iteración, se escoge una BL, de entre dos métodos, para la fase de intensificación. Una de ellas es el algoritmo MTS LS-1 [12], específicamente diseñado para LSGO. La otra es el clásico L-BFGS-B [13], que usa una

aproximación del gradiente para mejorar la búsqueda. Ambos métodos son complementarios: MTS LS-1 es muy rápido y apropiado para problemas separables, pero muy sensible a rotaciones. Por otro lado, L-BFGS-B es menos potente pero también menos sensible a estas.

Este *framework*, presentado en el algoritmo 1, es común a la anterior propuesta [8]. Sin embargo, como mencionamos antes, existen tres diferencias principales entre ambas propuestas: el algoritmo de ED utilizado (SHADE en lugar de SaDE) (línea 6), la selección de la BL (líneas 9 y 11) y el mecanismo de reinicio (líneas 15-17). En los párrafos siguientes vamos a detallar las principales características de la nueva propuesta.

### II-A. Algoritmo exploratorio: SHADE

En este trabajo, aplicamos SHADE como el componente exploratorio. Este algoritmo presenta las siguientes ventajas:

- Tiene un mecanismo de auto-ajuste de los parámetros de la ED, CR (parámetro del cruce) y F (parámetro de la mutación), sofisticado, que permite un ajuste óptimo a cada problema. El único parámetro que hay que fijar es el tamaño de población.
- El operador de mutación tiene en cuenta soluciones anteriores almacenadas en un archivo, lo cual incrementa la diversidad de las nuevas soluciones.
- El operador de mutación está sesgado para no seleccionar siempre la mejor solución. En su lugar, selecciona aleatoriamente de entre las  $p$  mejores soluciones.

Una descripción más detallada del algoritmo SHADE se puede encontrar en [10].

En algunas versiones más recientes de SHADE, algunos autores incorporan una reducción lineal del tamaño de la población al considerar que es demasiado exploratorio [11], [14]. Sin embargo, en nuestro caso, es ésta precisamente la característica que más nos interesa, ya que disponemos de otros métodos de intensificación, por lo que no necesitamos aplicar la reducción del tamaño de la población. Es más, habiendo probado ambas versiones, los mejores resultados los hemos obtenidos con SHADE.

### II-B. Selección de la BL

En IHDELS, la selección de la BL en cada iteración se llevaba a cabo con una determinada probabilidad (línea 9)  $P_{LS}$ . Este valor se inicializaba como  $P_{LS} = \frac{1}{|LS|}$ , donde  $|LS|$  es el número de métodos de BL (2 en nuestro caso) disponibles. Además, en cada iteración (línea 11) la mejora de cada método de BL se calculaba como:

$$I_{LS} = \frac{fitness(Before_{LS}) - fitness(After_{LS})}{Before_{LS}} \quad (1)$$

A continuación, la probabilidad de seleccionar cada BL se ajustaba según el valor medio de  $I_{LS}$  obtenido por cada método de BL.

En SHADE-ILS, la mejora de cada método de BL se calcula del mismo modo (ecuación 1). Sin embargo, en lugar de usar el  $I_{LS}$  medio para cada BL, selecciona la BL con mayor  $I_{LS}$



durante la última aplicación. Este criterio es más simple y, en nuestros experimentos, más eficiente que el anterior. No sólo eso: cuando el rendimiento de un método de BL decrece rápidamente, el uso del  $I_{LS}$  medio requiere de más tiempo para detectar este cambio, mientras que el uso del  $I_{LS}$  de la anterior ejecución proporciona una adaptación más rápida.

### II-C. Mecanismo de reinicio

En ocasiones, un proceso de optimización puede estancarse. En esas situaciones, una solución muy común consiste en incluir un mecanismo que detecte cuándo la mejor solución no puede ser mejorada y se encargue de reiniciar la población.

En IHDELS, el criterio de reinicio (línea 16) sólo se cumplía cuando no se conseguía mejorar durante una iteración completa. Sin embargo, en optimización continua es bastante frecuente que se siga mejorando ligeramente la mejor solución en el entorno de un atractor. Esto hacía que el mecanismo de reinicio inicialmente propuesto sólo se aplicase unas pocas veces, y en esos casos, con poco éxito.

En este trabajo, proponemos un mecanismo de reinicio que se aplica cuando, durante tres iteraciones consecutivas, el ratio de mejora (teniendo en cuenta tanto la ED como la BD) es menor del 5%. En esos casos, el mecanismo de reinicio se aplica de la siguiente manera:

- Se selecciona, aleatoriamente, una solución  $sol$ .
- Se aplica una perturbación a  $sol$  que siga una distribución normal de media 0 y desviación típica un 10% del dominio de búsqueda:  $current_{best} = sol + rand_i \cdot 0,1 \cdot (b - a)$ , donde  $rand_i$  devuelve un número aleatorio  $rand_i \in [0, 1]$  y  $[a, b]$  es el dominio de búsqueda.
- La población del algoritmo se reinicia aleatoriamente.
- Los parámetros adaptativos de los métodos de BL se reinician a sus valores por defecto.

Normalmente, las poblaciones se suelen reiniciar de manera aleatoria (o a partir de perturbaciones sobre la mejor solución encontrada hasta ese momento). Lo que nosotros proponemos es seleccionar una solución aleatoriamente de la población de la ED con el objetivo de que sea una solución razonablemente buena pero que no haya sido mejorada todavía por la BL. Sobre ésta, realizamos una pequeña perturbación para evitar que la siguiente población sea muy parecida a la actual.

Por otro lado, cuando la BL no es capaz de mejorar la mejor solución, también se reinician sus parámetros.

Permitir tres iteraciones completas antes de reiniciar completamente la población sigue la lógica de permitir al algoritmo que aplique ambas búsquedas locales y que éstas pueden, a su vez, reiniciar sus parámetros. Si no se producen mejoras significativas después de estas tres iteraciones, se aplica el reinicio de la población tal y como se describió con anterioridad.

## III. EXPERIMENTACIÓN

Para la experimentación hemos seguido las directrices de la competición de LSGO del CEC 2013 [15]. Este benchmark se compone de 15 funciones de 1000 dimensiones y varios niveles de separabilidad, desde funciones completamente

separables a completamente no-separables. La descripción detallada del benchmark puede encontrarse en [15].

La implementación del algoritmo se ha realizado en Python, y está libremente disponible<sup>1</sup>. Cada algoritmo se ha ejecutado 51 veces, y cada ejecución finaliza cuando se alcanza un número máximo de evaluaciones de fitness,  $FES$  por sus siglas en inglés, que se fija en  $3 \cdot 10^6$ . Además, se registra el mejor  $fitness$  en distintos puntos de control (en términos de  $FES$ , que son, en este caso, los siguientes:  $\{1, 2, 3, 0, 6, 0, 9, 0, 12, 15, 18, 21, 24, 27, 30\} \cdot 10^5$ . Sin embargo, como en anteriores competiciones sólo se tenían en cuenta tres puntos de control ( $1, 2 \cdot 10^5$ ,  $6, 0 \cdot 10^5$ ,  $3, 0 \cdot 10^6$ ), usaremos éstos para las comparativas con algoritmos del estado del arte.

La Tabla I recoge la configuración de parámetros usados en esta experimentación. En dicha tabla se puede comprobar cómo se ha establecido un número de evaluaciones de 50000 para cada iteración (25000 de las cuales son usadas por la ED y las otras 15000 por la BL). El resto de parámetros, compartidos entre IHDELS y SHADE-ILS, se mantienen sin cambios.

Tabla I: Configuración de parámetros

Algoritmo	Parámetro	Descripción	valor
Parámetros Compartidos	ED popsize	Tamaño de población	100
	$FES_{ED}$	FES para la ED	25000
	$FES_{BL}$	FES para la BL	25000
	$MTS_{Istep}$	Paso inicial para MTS-LS1	20
IHDELS	$Freq_{BL}$	Frec. actualización de prob.	10
SHADE-ILS	$Restart_N$	Iteraciones sin mejora	3
IHDELS	$Threshold$	Ratio de mejora mínimo	5%

Los resultados de nuestra propuesta quedan recogidos en la Tabla II. Las siguientes secciones de esta contribución discuten acerca de estos resultados. En primer lugar, analizamos la contribución de las distintas componentes de nuestra propuesta, con especial interés en el mecanismo de reinicio. A continuación, comparamos los resultados con los del algoritmo IHDELS, en el que se basa esta propuesta. Por último, compararemos los resultados con los del actual ganador de las últimas competiciones de LSGO, MOS.

### III-A. Influencia de las distintas componentes

En esta sección analizamos la contribución de cada una de las subcomponentes de SHADE-ILS a los resultados globales.

En primer lugar, vamos a estudiar la contribución del nuevo mecanismo de reinicio y a compararlo con el método anterior a través del análisis de varias funciones representativas (Figura 1). Hay algunas funciones, como  $F_4$ , donde el nuevo mecanismo de reinicio mejora al anterior pero que presentan curvas de convergencia con una tendencia similar. En otros casos, como en  $F_5$ , el nuevo mecanismo de reinicio permite al algoritmo una exploración completa de la zona del óptimo, lo cual facilita una mejora rápida y continuada de la mejor solución. Por último, hemos observado, para varias funciones (como

<sup>1</sup><https://github.com/dmolina/shadeils>

Tabla II: Resultados de SHADE-ILS en el benchmark del CEC 2013

Punto de Control	Estadístico	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$	$f_7$	$f_8$
1.20e+05	Mejor	1.55e+04	2.25e+03	2.01e+01	1.53e+10	1.53e+06	1.04e+06	1.75e+08	3.22e+13
	Mediana	6.07e+04	2.57e+03	2.01e+01	2.60e+10	2.50e+06	1.05e+06	3.61e+08	1.62e+14
	Peor	1.42e+05	3.07e+03	2.12e+01	7.50e+10	3.28e+06	1.06e+06	9.46e+08	1.06e+15
	Desv. Típica	6.10e+04	2.65e+03	2.03e+01	3.13e+10	2.50e+06	1.05e+06	3.95e+08	2.12e+14
6.00e+05	Mejor	0.00e+00	1.43e+03	2.00e+01	7.60e+08	1.29e+06	1.02e+06	4.72e+05	8.82e+11
	Mediana	5.07e-25	1.74e+03	2.01e+01	1.26e+09	2.28e+06	1.04e+06	7.66e+05	6.17e+12
	Peor	2.27e-22	2.44e+03	2.01e+01	4.26e+09	3.08e+06	1.05e+06	2.70e+06	1.94e+13
	Desv. Típica	3.71e-23	1.80e+03	2.01e+01	1.54e+09	2.29e+06	1.04e+06	9.25e+05	6.93e+12
3.00e+06	Mejor	0.00e+00	8.53e+02	2.00e+01	5.95e+07	1.09e+06	1.00e+06	7.65e+00	1.81e+10
	Mediana	0.00e+00	9.88e+02	2.01e+01	1.15e+08	1.41e+06	1.02e+06	5.46e+01	2.78e+11
	Peor	6.73e-23	1.21e+03	2.01e+01	3.86e+08	1.86e+06	1.04e+06	1.99e+02	1.33e+12
	Desv. Típica	2.69e-24	1.00e+03	2.01e+01	1.48e+08	1.39e+06	1.02e+06	7.41e+01	3.17e+11
		1.35e-23	8.90e+01	1.12e-02	8.72e+07	2.03e+05	1.19e+04	5.46e+01	3.06e+11
Punto de Control	Estadístico	$f_9$	$f_{10}$	$f_{11}$	$f_{12}$	$f_{13}$	$f_{14}$	$f_{15}$	
1.20e+05	Mejor	2.15e+08	9.32e+07	1.98e+09	2.09e+03	4.74e+09	5.15e+10	6.12e+07	
	Mediana	2.88e+08	9.43e+07	4.23e+09	2.57e+03	1.30e+10	1.14e+11	8.11e+07	
	Peor	3.52e+08	9.50e+07	3.46e+10	4.08e+03	2.57e+10	5.12e+11	1.58e+08	
	Desv. Típica	2.88e+08	9.43e+07	6.55e+09	2.67e+03	1.29e+10	1.62e+11	9.12e+07	
6.00e+05	Mejor	3.48e+07	4.90e+05	7.26e+09	4.86e+02	5.97e+09	1.08e+11	2.57e+07	
	Mediana	1.93e+08	9.08e+07	7.85e+07	5.97e+02	1.72e+07	4.62e+07	5.76e+06	
	Peor	2.51e+08	9.30e+07	1.24e+08	1.33e+03	4.10e+07	6.42e+07	1.29e+07	
	Desv. Típica	3.07e+08	9.39e+07	2.73e+08	1.89e+03	3.84e+08	1.24e+08	3.10e+07	
3.00e+06	Mejor	2.50e+08	9.29e+07	1.37e+08	1.28e+03	5.68e+07	6.97e+07	1.22e+07	
	Mediana	3.08e+07	7.64e+05	4.74e+07	2.98e+02	7.27e+07	1.82e+07	6.30e+06	
	Peor	1.30e+08	9.06e+07	3.10e+05	8.53e-20	3.52e+04	4.93e+06	3.91e+05	
	Desv. Típica	1.63e+08	9.20e+07	4.50e+05	3.99e+00	8.28e+04	5.75e+06	6.09e+05	
		1.94e+08	9.31e+07	1.43e+06	2.99e+02	3.31e+05	6.39e+06	1.56e+06	
		1.64e+08	9.18e+07	5.11e+05	6.18e+01	1.00e+05	5.76e+06	6.25e+05	
		1.57e+07	6.93e+05	2.25e+05	1.04e+02	7.19e+04	3.76e+05	2.40e+05	

$F_9$  o  $F_{12}$ ) que el nuevo mecanismo de reinicio es capaz de incrementar significativamente la velocidad de convergencia.

A continuación, vamos a comparar la influencia de cada una de las subcomponentes de manera individual. La Tabla III presenta los resultados partiendo del algoritmo IHDELS y aplicando los distintos cambios descritos en la Sección II:

- IHDELS: Versión original de IHDELS propuesta en 2015 [8], que usa SaDE y el mecanismo de reinicio original.
- IHDELS-S: Algoritmo que reemplaza SaDE por SHADE pero manteniendo el mismo mecanismo de reinicio.
- IHDELS-R: Algoritmo con el nuevo mecanismo de reinicio pero manteniendo SaDE en lugar de SHADE.
- IHDELS-SR: Propuesta final, usando SHADE en lugar de SaDE y el nuevo mecanismo de reinicio.

En el análisis anterior no incluimos el nuevo mecanismo de selección de la BL porque las diferencias no eran evidentes. No obstante, decidimos mantener dicho cambio ya que reduce la complejidad del algoritmo al eliminar el parámetro  $Freq_{BL}$  sin deterioro de la calidad de las soluciones.

Analizando los resultados de la Tabla III se pueden extraer las siguientes conclusiones:

- El cambio en el mecanismo de reemplazo tiene un efecto mayor que el de la componente de ED.
- El uso de SHADE en lugar de SaDE mejora los resultados significativamente, independientemente del mecanismo de reinicio utilizado, especialmente en el caso de las funciones no-separables y con solapamiento.

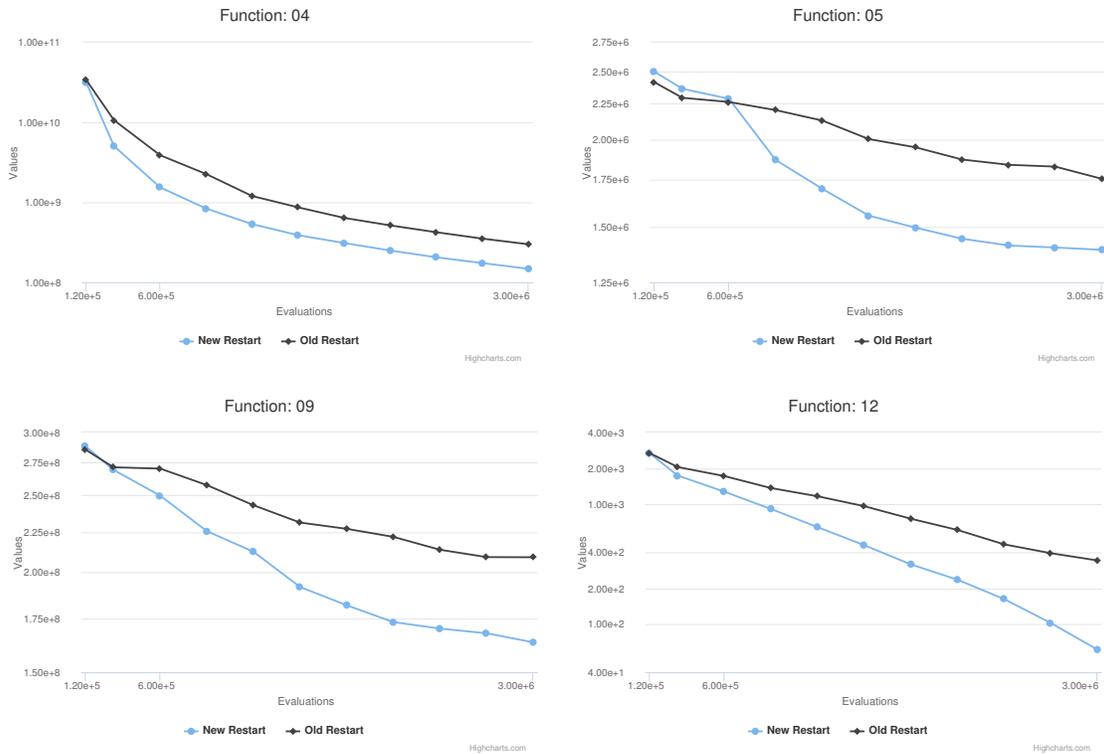
 Tabla III: Resultados para las diferentes combinaciones de las componentes del algoritmo tras  $3 \cdot 10^6$  FEs

Func.	IHDELS-SR (SHADE-ILS)	IHDELS-R	IHDELS-S	IHDELS original
$F_1$	2.69e-24	1.21e-24	1.76e-28	<b>4.80e-29</b>
$F_2$	<b>1.00e+03</b>	1.26e+03	1.40e+03	1.27e+03
$F_3$	2.01e+01	2.01e+01	2.01e+01	<b>2.00e+01</b>
$F_4$	<b>1.48e+08</b>	1.58e+08	2.99e+08	3.09e+08
$F_5$	<b>1.39e+06</b>	3.07e+06	1.76e+06	9.68e+06
$F_6$	<b>1.02e+06</b>	1.03e+06	1.03e+06	1.03e+06
$F_7$	<b>7.41e+01</b>	8.35e+01	2.44e+02	3.18e+04
$F_8$	<b>3.17e+11</b>	3.59e+11	8.55e+11	1.36e+12
$F_9$	<b>1.64e+08</b>	2.48e+08	2.09e+08	7.12e+08
$F_{10}$	<b>9.18e+07</b>	9.19e+07	9.25e+07	9.19e+07
$F_{11}$	5.11e+05	<b>4.76e+05</b>	5.20e+05	9.87e+06
$F_{12}$	<b>6.18e+01</b>	1.10e+02	3.42e+02	5.16e+02
$F_{13}$	<b>1.00e+05</b>	1.34e+05	9.61e+05	4.02e+06
$F_{14}$	<b>5.76e+06</b>	6.14e+06	7.40e+06	1.48e+07
$F_{15}$	<b>6.25e+05</b>	8.69e+05	1.01e+06	3.13e+06
<b>Mejor</b>	12	1	0	2

- La combinación de SHADE y el nuevo mecanismo de reinicio es significativamente mejor que cualquiera de las otras combinaciones, lo cual pone de manifiesto que existe una interacción positiva entre ambas mejoras.
- El algoritmo propuesto obtiene los mejores resultados en 12 de las 15 funciones del benchmark, siendo las



Figura 1: Comparativa del error medio para el mecanismo de reinicio original y el nuevo



diferencias muy pequeñas en las otras 3.

En resumen, las diferentes componentes de SHADE-ILS, especialmente el nuevo mecanismo de reinicio y el uso de SHADE en lugar de SaDE, son capaces de mejorar claramente los resultados de IHDELS. Es más, la combinación de todos estos nuevos componentes obtiene los mejores resultados, que son significativamente mejores que los de cualquier otra combinación posible.

### III-B. Comparación de SHADE-ILS e IHDELS

En la Tabla III se puede observar que SHADE-ILS es mejor que IHDELS en 13 de las 15 funciones del benchmark (con diferencias mínimas en las otras dos). No sólo eso: las mejoras de SHADE-ILS son especialmente importantes en las funciones más complejas, donde obtiene un error al menos un orden de magnitud más pequeño en muchas de ellas (por ejemplo, en las funciones  $F_5, F_7, F_8, F_{11}, F_{12}, F_{13}, F_{14}$ , o  $F_{15}$ ). Como acabamos de discutir, las mejoras son debidas a la combinación de ambas componentes. Por último, el cambio en el mecanismo de selección de la BL elimina un parámetro del algoritmo ( $F_{eqLS}$ ) y lo hace, por tanto, más sencillo, mientras sigue manteniendo un comportamiento robusto.

### III-C. Comparación de SHADE-ILS y MOS

En esta sección vamos a comparar SHADE-ILS con MOS, el algoritmo de referencia en LSGO y, desde 2013, el ganador de todas las competiciones en alta dimensionalidad. Ningún otro algoritmo ha sido capaz de mejorar sus resultados hasta

ahora, por lo que se puede considerar el actual *estado-del-arte* y, por tanto, la referencia clara que aspiramos a superar.

En la Tabla IV se presentan los resultados de SHADE-ILS y MOS para los distintos puntos de control ( $1,2 \cdot 10^5$ ,  $6 \cdot 10^5$ , y  $3 \cdot 10^6$ ), de los que podemos extraer las siguientes conclusiones:

- MOS obtiene los mejores resultados tras  $1,2 \cdot 10^5$  FEs, éstos se igualan tras  $6 \cdot 10^5$  FEs y, para el máximo número de FEs,  $3 \cdot 10^6$ , SHADE-ILS obtiene los mejores resultados en 10 de las 15 funciones.
- MOS sigue obteniendo los mejores resultados en las funciones separables ( $f_1$ - $f_3$ ), mientras que SHADE-ILS es mejor en funciones más complejas: con la excepción de las funciones  $f_6$  y  $f_{10}$ , SHADE-ILS es significativamente mejor en el resto de las funciones.
- SHADE-ILS es muy competitivo en un número mayor de funciones, especialmente en las solapadas y no-separables. No sólo mejora los resultados de MOS en muchos casos, sino que sus resultados son, a menudo, al menos un orden de magnitud más pequeños.

## IV. CONCLUSIONES

En este artículo hemos propuesto un nuevo algoritmo de optimización especialmente diseñado para Optimización Global de Alta Dimensionalidad, SHADE-ILS, que combina la capacidad exploratoria de una ED adaptativa con la capacidad de intensificación de dos métodos de BL. En cada iteración del algoritmo, éste evoluciona una población con SHADE y, a continuación, selecciona la BL con el mejor rendimiento

Tabla IV: Resultados obtenidos por SHADE-ILS y MOS para los distintos puntos de control:  $FEs=1,2 \cdot 10^5$ ,  $FEs=5,0 \cdot 10^5$  y  $FEs=3,0 \cdot 10^6$ .

Función	1.20e+05		6.00e+05		3.00e+06	
	SHADE-ILS	MOS	SHADE-ILS	MOS	SHADE-ILS	MOS
$F_1$	<b>6.10e+04</b>	2.71e+07	<b>3.71e-23</b>	3.48e+00	2.69e-24	<b>0.00e+00</b>
$F_2$	2.65e+03	<b>2.64e+03</b>	1.80e+03	<b>1.78e+03</b>	1.00e+03	<b>8.32e+02</b>
$F_3$	2.03e+01	<b>7.85e+00</b>	2.01e+01	<b>1.33e-10</b>	2.01e+01	<b>9.17e-13</b>
$F_4$	<b>3.13e+10</b>	3.47e+10	<b>1.54e+09</b>	2.56e+09	<b>1.48e+08</b>	1.74e+08
$F_5$	<b>2.50e+06</b>	6.96e+06	<b>2.29e+06</b>	6.95e+06	<b>1.39e+06</b>	6.94e+06
$F_6$	1.05e+06	<b>3.11e+05</b>	1.04e+06	<b>1.48e+05</b>	1.02e+06	<b>1.48e+05</b>
$F_7$	3.95e+08	<b>3.46e+08</b>	<b>9.25e+05</b>	8.19e+06	<b>7.41e+01</b>	1.62e+04
$F_8$	<b>2.12e+14</b>	3.72e+14	<b>6.93e+12</b>	8.41e+13	<b>3.17e+11</b>	8.00e+12
$F_9$	<b>2.88e+08</b>	4.29e+08	<b>2.50e+08</b>	3.84e+08	<b>1.64e+08</b>	3.83e+08
$F_{10}$	9.43e+07	<b>1.16e+06</b>	9.29e+07	<b>9.03e+05</b>	9.18e+07	<b>9.02e+05</b>
$F_{11}$	6.55e+09	<b>3.13e+09</b>	<b>1.37e+08</b>	8.05e+08	<b>5.11e+05</b>	5.22e+07
$F_{12}$	<b>2.67e+03</b>	1.16e+04	<b>1.28e+03</b>	2.20e+03	<b>6.18e+01</b>	2.47e+02
$F_{13}$	1.29e+10	<b>8.37e+09</b>	<b>5.68e+07</b>	8.10e+08	<b>1.00e+05</b>	3.40e+06
$F_{14}$	1.62e+11	<b>4.61e+10</b>	<b>6.97e+07</b>	2.03e+08	<b>5.76e+06</b>	2.56e+07
$F_{15}$	9.12e+07	<b>1.45e+07</b>	1.22e+07	<b>6.26e+06</b>	<b>6.25e+05</b>	2.35e+06

relativo durante la última fase de activación para que mejora la mejor solución encontrada por el algoritmo poblacional. Además, se ha incorporado un mecanismo de reinicio que permite al algoritmo explorar otras regiones del espacio de búsqueda cuando ésta se queda estancada (cuando la mejora relativa es pequeña durante varias iteraciones consecutivas).

En la sección de experimentación, hemos puesto a prueba SHADE-ILS usando el benchmark propuesto para la competición de alta dimensionalidad del CEC 2013. En primer lugar, hemos comprobado que cada una de las modificaciones llevadas a cabo sobre IHDELS contribuye significativamente a la mejora de los resultados. A continuación, hemos comparado la propuesta con el algoritmo de referencia en alta dimensionalidad, MOS. En esta comparación, SHADE-ILS consigue los mejores resultados, batiendo a MOS por primera vez desde 2013. Esta comparación revela que SHADE-ILS es especialmente competitivo en las funciones más complejas, con componentes solapadas y no separables, donde no sólo obtiene el error más pequeño en la mayoría de las funciones, sino que también consigue reducir el error en al menos un orden de magnitud en muchas de ellas.

Como trabajo futuro, vamos a probar otras técnicas para acelerar la convergencia del algoritmo y obtener mejores resultados en más funciones no-separables.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por ayudas del Ministerio de Ciencia, Innovación y Universidades (TIN2014-57481-C2-2-R, TIN2016-8113-R, TIN2017-83132-C2-2-R y TIN2017-89517-P) y de la Junta de Andalucía (P12-TIC-2958).

#### REFERENCIAS

[1] K. V. Price, R. M. Rainer, and J. A. Lampinen, *Differential Evolution: A Practical Approach to Global Optimization*. Springer-Verlag, 2005.  
 [2] S. Dasa, S. Maity, B.-Y. Qu, and P. Suganthan, "Real-parameter evolutionary multimodal optimization—a survey of the state-of-the-art," *Swarm and Evolutionary Computation*, vol. 1, no. 2, pp. 71–78, 2011.

[3] N. Xiong, D. Molina, M. L. Ortiz, and F. Herrera, "A walk into meta-heuristics for engineering optimization: principles, methods and recent trends," *International Journal of Computational Intelligence Systems*, 2015, vol. 8, no. 4, pp. 606–636, June 2015.  
 [4] M. N. Omidvar, X. Li, and X. Yao, "Cooperative Co-evolution with delta grouping for large scale non-separable function optimization," in *2010 IEEE Congress on Evolutionary Computation (CEC 2010)*. IEEE, 2010, pp. 1762–1769.  
 [5] M. N. Omidvar, X. Li, Y. Mei, and X. Yao, "Cooperative co-evolution with differential grouping for large scale optimization," *IEEE Transactions on Evolutionary Computation*, vol. 18, no. 3, pp. 378–393, June 2014.  
 [6] A. LaTorre, S. Muelas, and J. M. Peña, "Large Scale Global Optimization: Experimental Results with MOS-based Hybrid Algorithms," in *2013 IEEE Congress on Evolutionary Computation (CEC 2013)*, Cancún, Mexico, 2013, pp. 2742–2749.  
 [7] A. LaTorre, S. Muelas, and J. Peña, "A Comprehensive Comparison of Large Scale Global Optimizers," *Information Sciences*, vol. 316, pp. 517–549, 2014.  
 [8] D. Molina and F. Herrera, "Iterative hybridization of DE with local search for the CEC'2015 special session on large scale global optimization," in *2015 IEEE Congress on Evolutionary Computation (CEC 2015)*. IEEE, 2015, pp. 1974–1978.  
 [9] A. Qin, V. Huang, and P. Suganthan, "Differential Evolution Algorithm With Strategy Adaptation for Global Numerical Optimization," *IEEE Transactions on Evolutionary Computation*, vol. 13, no. 2, pp. 398–417, Apr. 2009.  
 [10] R. Tanabe and A. Fukunaga, "Evaluating the performance of shade on cec 2013 benchmark problems," in *2013 IEEE Congress on Evolutionary Computation*, June 2013, pp. 1952–1959.  
 [11] R. Poláková, J. Tvrđík, and P. Bujok, "L-shade with competing strategies applied to cec2015 learning-based test suite," in *2016 IEEE Congress on Evolutionary Computation (CEC)*, 2016, pp. 4790–4796.  
 [12] L. Y. Tseng and C. Chen, "Multiple Trajectory Search for Large Scale Global Optimization," in *2008 IEEE Congress on Evolutionary Computation (CEC 2008)*. IEEE Press, Jun. 2008, pp. 3052–3059.  
 [13] J. L. Morales and J. Nocedal, "Remark on algorithm 778: L-bfgs-b: Fortran subroutines for large-scale bound constrained optimization," *ACM Trans. Math. Softw.*, vol. 38, no. 1, pp. 7:1–7:4, Dec. 2011.  
 [14] J. Brest and B. M. Sepesy Mačec, "iL-SHADE: Improved L-SHADE Algorithm for Single Objective Real-Parameter Optimization Testing United Multi-operator Evolutionary Algorithms-II on Single Objective," in *2016 IEEE Congress on Evolutionary Computation (CEC)*, 2016, pp. 1188–1195.  
 [15] X. Li, K. Tang, M. N. Omidvar, Z. Yang, and K. Quin, "Benchmark functions for the CEC'2013 special session and competition on large scale global optimization," RMIT University, Tech. Rep., 2013.



# An insight into evolutionary algorithms for continuous optimization: Learning by competitions

1° Daniel Molina

*Department of Computer Science*  
*University of Granada*  
 Granada, Spain  
 dmolina@decsai.ugr.es

2° Antonio LaTorre

*DATSI, ETSIINF*  
*Center for Computational Simulation*  
*Universidad Politécnica de Madrid*  
 Madrid, Spain  
 atorre@fi.upm.es

3° Francisco Herrera

*Department of Computer Science*  
*University of Granada*  
 Granada, Spain  
 herrera@decsai.ugr.es

**Abstract**—During the recent years, continuous optimization has significantly evolved to become a mature research field, in which evolutionary and bio-inspired algorithms have an important role thanks to their good results with limited resources. Through the last ten years, there have been a number of competitions associated to special sessions in this area. In this study, we summarize, for different real-parameter competitions, the results, highlighting the most relevant algorithms and techniques, presenting the trajectory they have followed and how some of these works have deeply influenced the top performing algorithms of today. The aim is to be both a useful reference for researchers new to this interesting research topic and a useful guide for current researchers in the field.

**Index Terms**—Continuous optimization, global optimization, real-parameter optimization, large-scale global optimization.

## I. INTRODUCTION

Global optimization, also referred to as continuous or real-parameter optimization, is a growing research topic for its wide number of real-world applications. This optimization implies to optimize an *objective* function (we can consider minimize without loss of generality): to obtain  $x^*$  where  $f(x^*) \leq f(x), \forall x \in [a, b]$ , where  $a, b \in \mathbb{R}^N$  and  $f : \mathbb{R}^N \rightarrow \mathbb{R}$ .

Due to the immense domain search of some problems, it is usually not possible to perform an exhaustive search in the entire domain, so meta-heuristic algorithms [1], [2] or evolutionary algorithms [3] are usually applied. The recent and growing interest on this type of optimization has fostered the development of a huge number of optimization algorithms that deal with this type of optimization (and many more proposals arise each year). Unfortunately, the great number of proposals makes following the evolution of this field difficult, and there is no clear criterion to select the most adequate algorithms.

In order to give more visibility to the field, many special sessions have been proposed in international conferences. These special sessions have, frequently, an associated real-parameter optimization competition, in which multiple algorithms are evaluated on a specific benchmark to allow fair comparisons among them. Taking into consideration the results obtained in these competitions, the evolution of this research topic can be analyzed, and many interesting conclusions can be drawn.

In a recent work [4], we described the different real-coding optimization competitions, noting the benchmark used for each

one and briefly describing for each year the winners, obtaining several conclusions of the evolution of the competition. Also, we discussed several issues that we consider interesting about the research topic, the influence of winning algorithms over the years, and the evolution of real-parameter optimization. In this work, we summarize the main conclusions obtained in that paper. Due to the space limit, we have removed the references to the algorithms in this short summary. We refer the readers to the aforementioned full paper [4] for details.

## II. SEVERAL OPTIMIZATION COMPETITIONS

In our paper [4], we present the different global optimization competitions held at multiple international conferences and briefly describe the main algorithms (winner and runner-ups) for each year, according to the conclusions of the organizers. This review covers real-parameter, constraints, multi-modal and large-scale competitions.

As previously mentioned, space limits do not allow us to go into details in this paper. Instead, we preferred to focus on the main conclusions derived from our study. For the details on the results of each competition, we refer the readers to [4].

## III. CURRENT TRENDS AFTER A DECADE OF COMPETITIONS

In this section, we use the historical information after a decade of competitions in real-optimization to study which are the most influential algorithms, and the most successful components of those algorithms that have been, since their proposal, incorporated to other methods.

### A. Competitions winners and most influential algorithms

In any research field, a good indication of its evolution is to what extent some algorithms have influenced others over the years, reusing ideas from previous successful proposals. In this particular case, we concluded that there are three very influential algorithms: CMA-ES, L-SHADE and MVMO. Not only they have inspired an important number of variants, but they are also the roots of the majority of winners.

Since 2005, the most influential algorithm has been CMA-ES. Algorithms based on this approach, such as BIPOP-CMA-ES or Ni-BIPOP-aCMA, were the winners of the CEC'2005,

BBOB'2009 and CEC'2013 competitions, respectively. Furthermore, there are many algorithms inspired by CMA-ES that have won several editions of the BBOB competition. It has been used as a local search method (see DRMA-LSCh-CMA) or as a component in a hybrid algorithm such as, for example, in iCMAES-ILS, the winner of the CEC'2013 competition.

A second algorithm with an increasing influence is L-SHADE, the winner in 2014. Its good results have favored an interesting list of winners using it in CEC'2015 (two of the three best algorithms), CEC'2016 and CEC'2017 (the three winners, and also other algorithms).

A third algorithm with good results was the MVMO scheme algorithm, which proves that being a scheme is not only good for global optimization, but also when the number of allowed fitness evaluations is very scarce (as shown by its good behavior in the expensive benchmark). In this case, the different proposals came from the same authors, maybe because this method is still not as popular as the DE scheme.

Obviously, the algorithms with the best results in the competitions are the most influential. However, sometimes, such as with the SHADE or VMO algorithms, their first versions were not among the winners, but they were evolved and, over the next few years, other methods based on them performed better achieving winning positions. Furthermore, it is remarkable that the metaheuristics with the best results in these competitions are far from being bio-inspired algorithms. In this sense, these results remind us that the *novelty* of new metaheuristics is very important but also subordinated to their performance in solving optimization problems.

### B. Techniques/components for winner algorithms

One of the most interesting issues when studying successful algorithms is the identification of the different components that each algorithm uses, as they can be further used by other methods to boost their performance. In the following, we highlight several popular techniques/components that seem to provide good results:

- A frequent problem with many algorithms is the selection of appropriate values for their parameters. There are two alternatives: to be carefully chosen or an automatic parameter tuning tool. Another option, very popular in competitive algorithms, is to use self-adaptive criteria to adjust them, using an adaptive probability or a memory to enforce good parameter values.
- Several algorithms not only self-adapt their parameters, but also their components, having several components that provide the same functionality and then selecting one of them according to their performance.
- When the self-adaptive component is not a part of an optimization algorithm but of a complete algorithm, the proposal can be considered as a framework of algorithms. One proposal can be designed to have a particular combination, such as in the case of iCMAES-ILS, or allow a more open selection of optimization methods, as in MOS, the state-of-art algorithm in large-scale global optimization for more than six years.

- Most of the proposals are memetic algorithms. The local search method used relies on many different types of methods, from more general to specific approaches, such as the ones used in MTS and other LSGO algorithms.
- In order to increase the selective pressure in the populations, one approach popularized by L-SHADE and adopted by other algorithms is to decrease the population size during the run. In conjunction with a memory of solutions, it increases the exploitation ability of the algorithm, maintaining certain diversity in the search.
- Traditionally, in most of the best-performing methods only the best solutions were considered to guide the search. This means that a lot of information was being wasted in each generation. In more recent algorithms, bad solutions are also used to guide the search. Similarly, in the MVMO family of algorithms, not only is the best solution is considered, but also the average of a group of good solutions.

## IV. CONCLUSIONS

The use of Bio-inspired and Evolutionary Algorithms for real-parameter optimization is of great interest today, and thus many approaches based on this type of optimization are proposed each year. This large number of proposals makes it difficult for researchers to follow the evolution of the field. In this paper, we have presented some conclusions after a decade of competitions on this type of real-parameter optimization problems. We have observed that there are several algorithms, such as CMA-ES, L-SHADE, MVMO and MOS, that have exercised a strong influence over other algorithms. We have also suggested several techniques that are being widely adopted among the winning proposals, and which could be used for more competitive algorithms.

The objective of this review and analysis of the evolution of the competitions is to offer a useful reference to new researchers in this research topic, and to help them to continue improving the field.

## ACKNOWLEDGMENTS

This work was supported by grants from the Spanish Ministry of Science and the European Fund (FED-ER) under projects (TIN2014-57481-C2-2-R, TIN2016-8113-R, TIN2017-83132-C2-2-R, TIN2017-89517-P) and Regional Government (P12-TIC-2958).

## REFERENCES

- [1] F. Glover and G. A. Kochenberger, *Handbook of metaheuristics*. Springer, 2003.
- [2] N. Xiong, D. Molina, M. L. Ortiz, and F. Herrera, "A walk into metaheuristics for engineering optimization: principles, methods and recent trends," *International Journal of Computational Intelligence Systems*, 2015, vol. 8, no. 4, pp. 606-636, June 2015.
- [3] T. Bäck, D. B. Fogel, and Z. Michalewicz, Eds., *Handbook of Evolutionary Computation*. Bristol, UK: IOP Publishing Ltd., 1997.
- [4] D. Molina, A. LaTorre, and F. Herrera, "An insight into bio-inspired and evolutionary algorithms for global optimization: Review, analysis, and lessons learnt over a decade of competitions," *Cognitive Computation*, Apr 2018. [Online]. Available: <https://doi.org/10.1007/s12559-018-9554-0>

0

**XIII Congreso Español  
de Metaheurísticas,  
Algoritmos Evolutivos y  
Bioinspirados  
(XIII MAEB)**

MAEB 11:

COMPUTACIÓN EVOLUTIVA:  
FUNDAMENTOS Y MODELOS II







# Un estudio sobre la influencia de la función objetivo en evolución gramatical para regresión simbólica

J. Manuel Colmenar

Universidad Rey Juan Carlos

C/. Tulipán s/n, 28933, Móstoles, Spain

Email: josemanuel.colmenar@urjc.es

J. Ignacio Hidalgo

Universidad Complutense de Madrid

C/. Prof. José García Santesmases 9, 28040, Madrid, Spain

Email: hidalgo@dacya.ucm.es

**Resumen**—La evolución gramatical es una variante de la programación genética, que permite, entre otras características, introducir conocimiento del problema en el proceso de búsqueda. Una de las aplicaciones más importantes de esta técnica, al igual que de la programación genética tradicional, es la regresión simbólica. La regresión simbólica consiste en obtener expresiones matemáticas que modelen un conjunto de datos. Como todo algoritmo evolutivo, la búsqueda tiene que estar guiada por una función objetivo. Esta función objetivo, en el caso de la regresión simbólica, debe medir la proximidad de la función matemática reportada por el algoritmo a los datos objeto del problema. Por lo tanto, lo más habitual es utilizar el error cuadrático medio, el valor de  $R^2$ , o alguna otra variante de la diferencia entre los puntos. En este artículo investigamos la influencia de la utilización del error cuadrático medio y de  $R^2$  en el proceso de búsqueda y en la calidad de las soluciones obtenidas con evolución gramatical en problemas de regresión simbólica.

## I. INTRODUCCIÓN

Uno de los paradigmas más importantes en cuanto a las aplicaciones de la inteligencia artificial es la computación evolutiva y dentro de ella es de fundamental importancia la programación genética (PG, o GP, de sus siglas en inglés: *Genetic Programming*) [6]. La PG es una metodología que permite obtener de una forma automática programas que representen soluciones a problemas o que realicen una determinada función. Utiliza una representación de las soluciones en forma de árboles, lo que hace que en ocasiones el tamaño de memoria necesario para representar las soluciones de la población sea excesivo. Por ello se han desarrollado alternativas que funcionen bajo los mismos principios pero que permitan reducir tanto el espacio ocupado en memoria, como el tiempo efectivo de búsqueda de soluciones. La evolución gramatical, también conocida como gramáticas evolutivas (de una mala traducción del inglés, *Grammatical Evolution*) [7], es una variante de la programación genética en la que se utilizan una serie de reglas recogidas en una

gramática para construir los árboles que representan una solución. Esto permite introducir conocimiento del problema en el proceso de búsqueda y controlar el tamaño de los árboles que representan a las soluciones.

Una de las aplicaciones más relevantes de esta técnica, al igual que de la programación genética tradicional, es la regresión simbólica. La regresión simbólica consiste en obtener expresiones matemáticas que representen un conjunto de datos. Sus aplicaciones en la actualidad son innumerables ya que es una técnica fundamental en el análisis de datos y modelado de sistemas a partir de registros de información [3, 4]. Como todo algoritmo evolutivo, la búsqueda tiene que estar guiada por una función objetivo. Esta función objetivo, en el caso de la regresión simbólica, debe medir la proximidad de la función matemática reportada por el algoritmo a los datos objeto del problema. Por lo tanto, lo más habitual es utilizar el error cuadrático medio, el valor de  $R^2$ , o alguna otra variante de la diferencia entre los puntos. Sin embargo, aunque el objetivo buscado sea el mismo, al utilización de una u otra función puede tener consecuencias importantes en el resultado final del proceso de búsqueda.

En este artículo se analiza la influencia de la utilización del error cuadrático medio y de  $R^2$  tanto en el proceso de búsqueda como en la calidad de las soluciones obtenidas con evolución gramatical en problemas de regresión simbólica. Como se verá en la discusión del trabajo, a partir de las expresiones de las funciones objetivo, intuitivamente se puede pensar que cuando se utiliza el valor de  $R^2$  los resultados de la búsqueda deben reportar expresiones que tengan una alta correlación con los datos, pese a que no estemos obteniendo una función que represente exactamente todos los datos. Sin embargo, al utilizar el error cuadrático medio (*RMSE*, del inglés *Root Mean Square Error*) se esperaría que las buenas soluciones representen los datos de manera más fiel. Para realizar el estudio se han utilizado varios problemas clásicos de

regresión simbólica, y se han comparado los resultados utilizando gramáticas iguales con funciones objetivo diferentes. Los resultados muestran la diferencia entre los modelos y soluciones obtenidas así como la influencia de la función objetivo en estos resultados.

El resto del artículo está organizado como sigue. En la sección II se describe brevemente la técnica de la evolución gramatical. En la sección III se revisa el diferente enfoque de las funciones objetivo bajo estudio. La exposición de los resultados y su análisis se realiza en la sección IV y la sección V resume las principales conclusiones de este trabajo.

## II. EVOLUCIÓN GRAMATICAL

La evolución gramatical es un paradigma evolutivo que deriva de la programación genética. En resumen, la aportación de la evolución gramatical consiste en modificar la representación de los individuos utilizando cromosomas en lugar de árboles. Este cambio permite que se puedan utilizar operadores clásicos de algoritmos genéticos como el cruce, mutación o selección, cuya implementación es más sencilla y eficiente al ejecutar sobre cromosomas que sobre árboles. Además, para realizar la decodificación del cromosoma se utiliza una gramática, que incluye reglas de producción que permiten generar las expresiones que corresponden al fenotipo del individuo.

Pese a ser una técnica reciente, durante los últimos años se ha utilizado de forma extensa en problemas de modelado. Para mayor información sobre evolución gramatical se puede recurrir a los trabajos mencionados en la introducción y también acudir a [2] ó [5] para ver el detalle del proceso de decodificación.

Como ejemplo de gramática, la Figura 1 muestra la que se ha utilizado en los experimentos de este artículo. En particular, esta gramática corresponde al conjunto de datos de referencia Vladislavleva-F8 porque considera dos variables de entrada, como se indica en la última regla. Para el resto de las pruebas de referencia, esta regla será la única modificada, adaptada al número de variables de entrada.

## III. FUNCIONES OBJETIVO EN PROBLEMAS DE REGRESIÓN SIMBÓLICA

A continuación, se planteará la formulación de las funciones objetivo bajo estudio en este artículo. Siendo  $O$  el vector de valores observados (aquellos provenientes de la optimización) y  $E$  el vector de valores esperados (formado por la variable objetivo), y  $\bar{O}$  y  $\bar{E}$  los valores promedio de cada uno de ellos, las expresiones para las funciones objetivo son las siguientes:

```
# Rule to create the main structure of the
# produced expression
<expr> ::= (<expr> + <expr>) / (<expr> + <
  <expr>)
  | <expr> + <expr> | <expr> - <expr>
  | <expr> * <expr> | <expr> / <expr>
  | <c> | <c>.<c> | <c><c>.<c><c> | <
    <var> | <var>
  | <expr> <op> <expr> | <c>^<var>
  | exp(abs(<c> <op> <var>)) | log(abs
    (<c> <op> <var>))

# Digits
<c> ::= 0|1|2|3|4|5|6|7|8|9

# Arithmetic operands
<op> ::= +|-|*|/

# Input variables
<var> ::= X1 | X2
```

Figura 1: Gramática diseñada para abordar los experimentos. El ejemplo corresponde a Vladislavleva-F8, que trata 2 variables de entrada.

$$R^2 = \left( \frac{\sum_i ((E_i - \bar{E})(O_i - \bar{O}))}{\sqrt{\sum_i (E_i - \bar{E})^2 \sum_i (O_i - \bar{O})^2}} \right)^2$$

$$RMSE = \sqrt{\frac{1}{N} \sum_i (O_i - E_i)^2}$$

$R^2$  no es sólo una medida de la bondad de ajuste, sino también una medida de hasta qué punto el modelo (el conjunto de variables independientes que se seleccionó) explica el comportamiento (o la varianza) de su variable dependiente. Por lo tanto, si un modelo tiene una  $R^2$  de 0,6, esto explica el 60 % del comportamiento de su variable dependiente. Ahora, si se se usa el  $R^2$  Ajustado que esencialmente penaliza el  $R^2$  por el número de variables que usa el modelo, se puede obtener una idea bastante buena de cuándo hay que dejar de agregar variables al modelo (y eventualmente simplemente obtener un modelo que se ajuste). Si el  $R^2$  Ajustado de los modelos obtenidos con un conjunto de variables es 0,8, y al añadir una variable sólo aumenta en 0,01, lo más indicado es que no sea necesario añadir esa variable. Realmente, si el algoritmo de evolución gramatical está bien diseñado, esto no debe suceder ya que de inicio se habrán seleccionado las variables que intervienen y el propio algoritmo proporcionará un modelo que implícitamente indica qué variables son las más importantes, ya que son las que aparecen en el modelo.

En el caso de RMSE, éste devuelve una estimación de la desviación estándar de los residuales<sup>1</sup> [1]. Por

<sup>1</sup>La diferencia entre los valores reales y los estimados es el residual.



tanto, a mayor RMSE, mayor desviación estimada en los errores del modelo.

En principio, por tanto,  $R^2$  mide el ajuste de un modelo sobre un conjunto concreto de datos, mientras que RMSE mide la dispersión de los errores. A priori, podría parecer que estas medidas indican ambas la calidad de un modelo, por lo que podrían ser intercambiables. Sin embargo, como se verá en la sección de resultados, valores altos de una de las métricas no implican valores altos de la otra.

#### IV. RESULTADOS EXPERIMENTALES

Los experimentos de este artículo se han realizado sobre un conjunto de tres problemas de regresión estándar, que se denominarán *benchmarks* a partir de este punto, haciendo uso de la expresión comunmente utilizada en inglés. Estos problemas se han seleccionado como parte de los problemas recomendados para PG en [10], y son los siguientes: *Tower*, *Vladislavleva-F8* y *Spatial co-evolution*. A continuación se detallan algunas de las características de estos problemas:

- En el conjunto de datos *Spatial co-evolution* [8], la variable objetivo se define de la siguiente manera:

$$F(x, y) = \frac{1}{1 + x^{-4}} + \frac{1}{1 + y^{-4}}$$

En el conjunto de entrenamiento original existen 676 registros en los cuales los valores para las variables  $x$  e  $y$  se muestrean desde -5 a +5 en intervalos de 0.4. En el conjunto de test hay 1000 registros en los que las variables  $x$  e  $y$  se muestrean en el intervalo  $[-5, \dots, +5]$  aleatoriamente. En conjunto, forman un total de 1676 datos, y se han utilizado como serie de regresión al completo.

- El conjunto de datos *Tower* [9] proviene de un problema industrial sobre medidas de cromatografía de gases en una torre de destilación. El conjunto de datos contiene 5000 registros y 25 variables de entrada potenciales. La variable de respuesta es la concentración de propileno en la parte superior de la torre de destilación. Los datos de *Tower* se pueden descargar en <http://www.symbolicregression.com/?q=towerProblem>.
- El conjunto de datos *Vladislavleva-F8*, denotado como *VF8* a partir de este momento, define las variables de salida como funciones de  $x_1$  y  $x_2$ , de la siguiente manera:

$$F_8(x_1, x_2) = \frac{(x_1 - 3)^4 + (x_2 - 3)^3 - (x_2 - 3)}{(x_2 - 2)^4 + 10}$$

Para todos los *benchmarks* se han estudiado las dos funciones objetivo,  $R^2$  y *RMSE*, con dos tipos de inicialización para la primera población del algoritmo: inicialización aleatoria (*random*) e inicialización

*sensible*, que controla el tamaño de los fenotipos de los individuos de la generación inicial evitando que sean excesivamente grandes. De cada experimento se han realizado diez ejecuciones diferentes utilizando los mismos parámetros de entrada para el algoritmo de GE, que se muestran en la Tabla I. Los experimentos se ejecutaron en un ordenador equipado con un procesador Intel Core i7 a 2.9 GHz con 16 GB de RAM sobre sistema operativo Mac OSX 10.13.5.

Parámetro	Valor
Población	300 individuos
Generaciones	1700
Selección	Torneo (2 indiv.)
Prob. Cruce	80 %
Prob. Mutación	2 %
Función objetivo	$R^2$ ó <i>RMSE</i>
Inicialización	<i>random</i> , <i>sensible</i>
Longitud del Cromosoma	256
Número máximo de wraps	5

Tabla I: Valores de los parámetros utilizados en los experimentos.

El primer aspecto a analizar es la evolución de las ejecuciones a través del análisis del mejor individuo. Para ello, se tomó el valor de la función objetivo cada 100 generaciones, en cada una de las ejecuciones. Dado que se lanzaron 10 ejecuciones para cada experimento, los datos que se muestran se corresponden con el promedio de las 10 ejecuciones.

En primer lugar, las figuras 2 y 3 muestran la evolución para el caso de la inicialización con una población aleatoria (*random*), utilizando como función objetivo  $R^2$  y *RMSE* respectivamente. Dado que el algoritmo trata de minimizar, el valor que se presenta en el caso de  $R^2$  es en realidad  $1 - R^2$ , y así será para el resto de experimentos. Como se puede apreciar, el problema más difícil de resolver es *Tower*. Por otro lado, la evolución tiene una tendencia hacia abajo menos pronunciada a partir de la generación 500 aproximadamente en ambas gráficas.

Las figuras 4 y 5 muestran la convergencia para el caso de la inicialización *sensible*, utilizando como función objetivo  $1 - R^2$  y *RMSE* respectivamente. De nuevo, el comportamiento es similar en ambos casos, siendo *Tower* el problema más difícil. En el caso de la comparativa entre los diferentes tipos de inicialización, se puede ver que entre las figuras 2 y 4, que utilizan la misma función objetivo,  $1 - R^2$ , y diferente inicialización, la inicialización *sensible* alcanza mejores valores promedio a lo largo de toda la ejecución del algoritmo en los tres *benchmarks*.

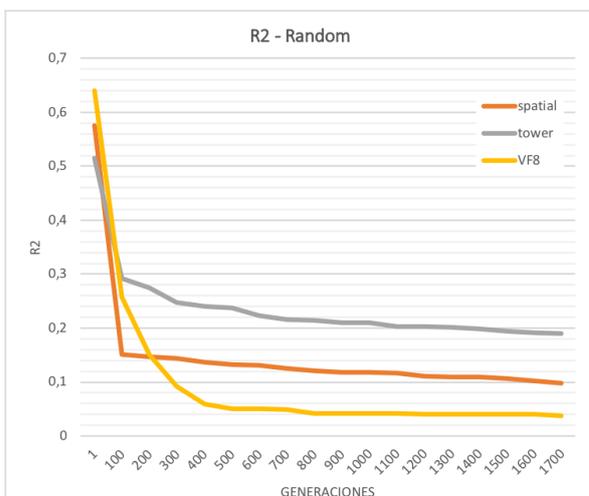


Figura 2: Valores promedio de la función objetivo:  $1 - R^2$ . Inicialización *random*.

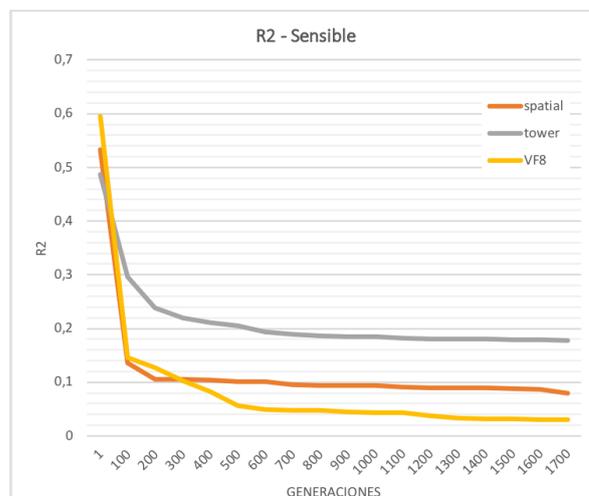


Figura 4: Valores promedio de la función objetivo:  $1 - R^2$ . Inicialización *sensible*.

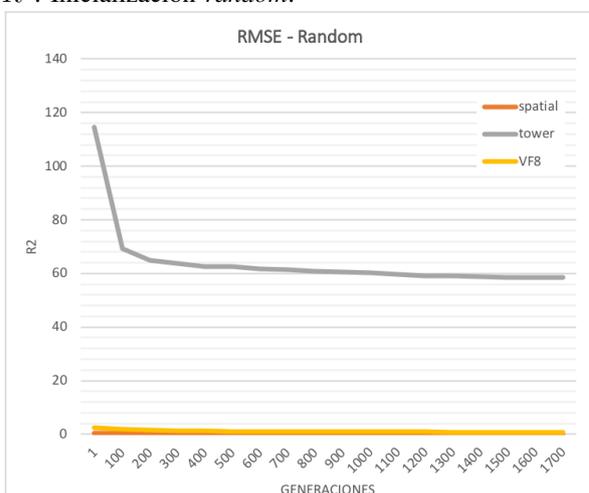


Figura 3: Valores promedio de la función objetivo: *RMSE*. Inicialización *random*.

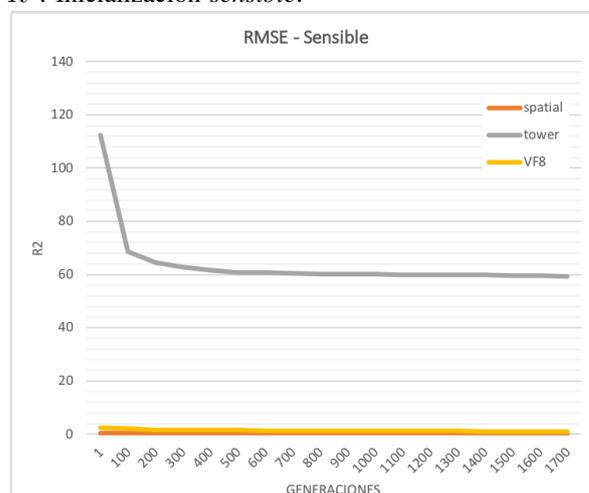


Figura 5: Valores promedio de la función objetivo: *RMSE*. Inicialización *sensible*.

En el caso de la optimización con *RMSE*, la inicialización *sensible* no aporta valores mejores en la evolución. A pesar de que la escala no permite ver las diferencias gráficamente en las figuras 3 y 5, sí que se aprecia que al principio los valores promedio son mejores, pero según avanza la evolución, los experimentos con inicialización aleatoria obtienen mejores valores promedio.

Independientemente de las funciones objetivo utilizadas, se han calculado los valores de  $R^2$  y *RMSE* para todas las soluciones obtenidas en los experimentos. La figuras 6 y 7 muestran, respectivamente, los valores promedio de  $R^2$  y *RMSE* para cada uno de los *benchmarks* en los diferentes casos. Se denota el experimento con optimización a través de  $R^2$  e inicialización aleatoria

como *R2-Random*; optimización a través de  $R^2$  e inicialización *sensible* como *R2-Sensible* y, de manera análoga, para *RMSE* y las dos inicializaciones estudiadas como *RMSE-Random* y *RMSE-Sensible*.

En la Figura 6 se puede apreciar cómo los valores de *R2-Random* y *R2-Sensible* son mayores que en la optimización con *RMSE*. En el caso, por ejemplo, de *Tower*, la diferencia es muy significativa, llegando a estar por encima del 30%. Los valores concretos de  $R^2$  se muestran en la Tabla III. Se puede apreciar también que la inicialización *sensible* mejora los resultados hasta en un 2% para los experimentos donde la función objetivo es  $1 - R^2$ .

La Figura 7 muestra los valores de *RMSE* para las mismas soluciones que se han utilizado en la

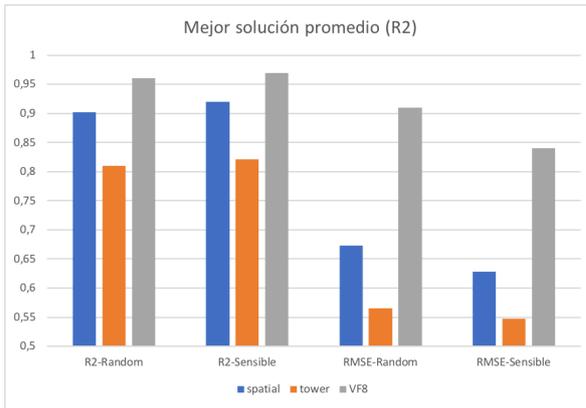


Figura 6: Valores promedio de  $R^2$  para los diferentes experimentos. Mejor cuanto más alto.

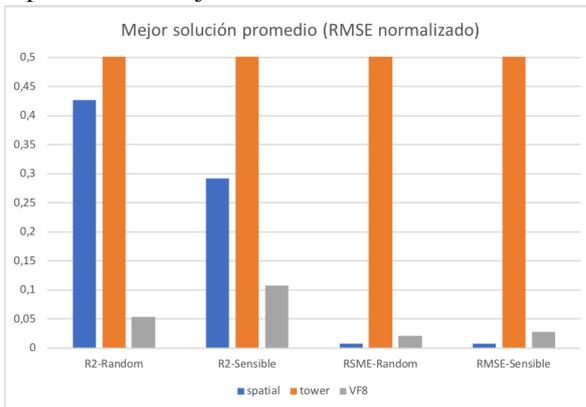


Figura 7: Valores promedio de  $RMSE$  normalizados para los diferentes experimentos. Mejor cuanto más bajo.

	spatial	tower	VF8
R2-Random	0,901794689	0,80986102	0,960807366
R2-Sensible	0,920002539	0,821656958	0,969546579
RMSE-Random	0,672605164	0,56536177	0,910126819
RMSE-Sensible	0,627583903	0,547273778	0,840721671

Tabla II: Valores promedio de  $R^2$ .

Figura 6. En este caso, dado que los valores presentan diferentes órdenes de magnitud, se han normalizado respecto a la décima parte del valor máximo. Los valores concretos de  $RMSE$  se presentan en la Tabla III. Como se puede apreciar, los valores de  $RMSE$  son mucho mejores en el caso de los algoritmos que utilizan esta métrica como función objetivo, llegando a obtener un orden de magnitud de diferencia. Resulta significativo señalar que la inicialización *sensible* no mejora los resultados en este caso. Al contrario, se llega a peores resultados en los tres problemas bajo estudio.

Estos resultados son coherentes con lo que se espera de algoritmo de optimización, que consigue la mejora

	spatial	tower	VF8
R2-Random	15,58366595	348,2669206	1,942964282
R2-Sensible	10,67370612	365,2646472	3,94804835
RMSE-Random	0,272769052	58,39444643	0,787039727
RMSE-Sensible	0,298058917	59,40281873	1,035522363

Tabla III: Valores promedio de  $RMSE$ .

en los valores de la función objetivo. Sin embargo, también demuestran que las funciones objetivo bajo estudio no son equivalentes.

Por un lado, la función objetivo  $R^2$  muestra la correlación entre dos series de valores. Una elevada correlación indica que la tendencia de las dos series es similar, independientemente del valor concreto del error entre el valor observado y el valor esperado. Un modelo con elevado valor de  $R^2$  puede conseguir buenas predicciones sobre valores no conocidos.

Por otro lado, la función objetivo  $RMSE$  muestra el error o diferencia entre una serie de predicciones y los datos esperados correspondientes. Al minimizar  $RMSE$  se reduce el error, por lo que la serie de predicciones se acerca a la serie esperada. La consecuencia es que se obtienen modelos cuya precisión es alta, pero cuya capacidad de predicción puede ser mala, debido al efecto de sobreajuste, también llamado *overfitting*.

Con objeto de evaluar la calidad de las soluciones obtenidas a través de una métrica diferente, se propone en este artículo la utilización de la métrica conocida como similitud del coseno. Esta medida interpreta ambas series de datos, observada y esperada, como vectores  $O$  y  $E$  respectivamente. De esta manera, se calcula el coseno del ángulo que forman ambos vectores utilizando la siguiente expresión:

$$\text{Coseno}(\theta) = \frac{\sum_i O_i E_i}{\sqrt{\sum_i O_i^2} \sqrt{\sum_i E_i^2}}$$

Si el valor del coseno es cercano a 1, entonces el ángulo que forman los vectores es cercano a  $0^\circ$ , por lo que se tratará de series similares. Si el valor es cercano a -1, entonces el ángulo es cercano a  $180^\circ$ , lo que significa que las series tienen tendencia similar, pero en sentido opuesto. En caso de que el valor del coseno esté cerca de 0, se trata de series perpendiculares, lo que se considera como la menor similitud posible. Sobre las soluciones obtenidas en los experimentos se ha calculado la similitud de coseno. La Tabla IV muestra los valores obtenidos para los experimentos donde la inicialización es aleatoria. Para cada *benchmark* se muestran los valores de las optimizaciones donde la función objetivo es  $1 - R^2$  ( $R_2$ ) y también los valores donde la función

de coste ha sido *RMSE*. Los valores presentados corresponden a las 10 ejecuciones realizadas. Como se aprecia en la tabla, los valores para *RMSE* son más altos y más consistentes, tal y como indican los valores promedio que se muestra en la última fila. En el caso de  $R^2$ , existen valores altos, cercanos al 1, pero también existen valores negativos y alguno cercano al 0, 5.

Run	spatial		tower		VF8	
	R2	RSME	R2	RSME	R2	RSME
1	0,9393	0,9931	0,9514	0,9881	0,9255	0,9758
2	0,9931	0,9666	0,96	0,9857	0,9865	0,9732
3	0,9807	0,9877	0,9541	0,9856	0,9782	0,9534
4	-0,7232	0,9962	0,9846	0,9886	0,9634	0,9736
5	0,9643	0,9897	0,9754	0,9838	0,8801	0,9434
6	0,5044	0,9698	-0,9682	0,9844	0,6949	0,9871
7	0,9608	0,9902	0,9655	0,9874	0,905	0,961
8	0,946	0,9723	-0,9826	0,9871	-0,9157	0,9535
9	0,9622	0,9905	0,9784	0,9874	0,9879	0,9487
10	0,9588	0,9914	0,9721	0,985	0,9824	0,9265
Avg.	0,7486	0,9847	0,5791	0,9863	0,7388	0,9596

Tabla IV: Similitud de coseno para los experimentos con inicialización *random*. La última fila muestra el valor promedio.

La Tabla V muestra las mismas estadísticas, pero para los experimentos donde la inicialización es *sensible*. De nuevo, la tendencia es la misma, aunque los resultados para los experimentos donde la función de coste es  $1 - R^2$  son peores en este caso. Es destacable el conjunto de resultados de *spatial*, que obtuvo el mejor promedio de  $R^2$  para la optimización *R2-Sensible* (ver Tabla II), mientras que los valores de similitud de coseno de ese mismo experimento son los peores, con dos valores por debajo de 0, 29.

Run	spatial		tower		VF8	
	R2	RSME	R2	RSME	R2	RSME
1	0,9966	0,9886	0,9391	0,9866	0,8819	0,9733
2	0,9705	0,9911	-0,965	0,9862	-0,9872	0,9673
3	0,9708	0,9914	0,9793	0,9844	-0,9889	0,9456
4	0,2871	0,982	-0,9777	0,987	0,9486	0,8021
5	0,9883	0,9743	0,9576	0,9863	0,6819	0,9566
6	0,9519	0,9762	0,9868	0,9856	0,9682	0,845
7	0,9112	0,9897	0,9611	0,9853	0,9178	0,8424
8	0,9634	0,9725	0,9687	0,9863	0,9484	0,953
9	0,957	0,9739	-0,9472	0,9863	0,9791	0,9485
10	0,1608	0,991	0,9707	0,9844	0,9199	0,9714
Avg.	0,8158	0,9831	0,3873	0,9858	0,527	0,9205

Tabla V: Similitud de coseno para los experimentos con inicialización *sensible*.

### V. CONCLUSIONES Y TRABAJO FUTURO

A la vista de los experimentos realizados en este artículo, se puede afirmar que  $R^2$  y *RMSE* no son funciones que lleven a soluciones equivalentes en todos los casos. Muy al contrario, pueden obtener resultados realmente diversos. Sin embargo, este es un estudio muy preliminar que se deberá extender en el futuro.

### AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía y Competitividad de España a través de los proyectos con referencias TIN2014-54806-R y TIN2015-65460-C2.

### REFERENCIAS

- [1] D. L. J. Alexander, A. Tropsha, and David A. Winkler. Beware of  $r^2$ : Simple, unambiguous assessment of the prediction accuracy of qsar and qspr models. *Journal of chemical information and modeling*, 55.7:1316–1322, 2015.
- [2] J. M. Colmenar and J. I. Hidalgo. Análisis de algoritmos de evolución gramatical en problemas de regresión simbólica. In *XII Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB 2017)*, pages 901–910, Barcelona, Spain, 2017. Universitat Pompeu Fabra.
- [3] Ian Dempsey, Michael O’Neill, and Anthony Brabazon. Live trading with grammatical evolution. In *GECCO 2004 Workshop Proceedings*, Seattle, Washington, USA, 26-30 June 2004.
- [4] J. Ignacio Hidalgo, J. Manuel Colmenar, José L. Risco-Martin, Alfredo Cuesta-Infante, Esther Maqueda, Marta Botella, and José Antonio Rubio. Modeling glycemia in humans by means of grammatical evolution. *Applied Soft Computing*, (20):40–53, 2014.
- [5] José Ignacio Hidalgo, J. Manuel Colmenar, José Luis Risco-Martín, Alfredo Cuesta-Infante, Esther Maqueda, Marta Botella, and José Antonio Rubio. Modeling glycemia in humans by means of grammatical evolution. *Appl. Soft Comput.*, 20:40–53, 2014.
- [6] J. R. Koza. *Genetic Programming*. The MIT Press, Cambridge, Massachusetts, 1992.
- [7] Michael O’Neill and Conor Ryan. Grammatical evolution. *IEEE Trans. Evolutionary Computation*, 5(4):349–358, 2001.
- [8] Ludo Pagie and Paulien Hogeweg. Evolutionary consequences of coevolving targets. *Evolutionary Computation*, 5:401–418, 1998.
- [9] E. J. Vladislavleva, G. F. Smits, and D. den Hertog. Order of nonlinearity as a complexity measure for models generated by symbolic regression via pareto genetic programming. *IEEE Transactions on Evolutionary Computation*, 13(2):333–349, April 2009.
- [10] David R. White, James McDermott, Mauro Castelli, Luca Manzoni, Brian W. Goldman, Gabriel Kronberger, Wojciech Jaskowski, Una-May O’Reilly, and Sean Luke. Better GP benchmarks: community survey results and proposals. *Genetic Programming and Evolvable Machines*, 14(1):3–29, Mar 2013.



# Un análisis preliminar de nuevos modelos de mutación dirigida en algoritmos genéticos.

B. Rodríguez-Puerta, Francisco Díaz-Barrancas, F. Chávez, F. Fernández de Vega  
 Dpto. de Ingeniería en Sistemas Informáticos y Telemáticos  
 Universidad de Extremadura  
 06800 Mérida, España.  
 Email: {brpuerta, frdiaz, fchavez, fcofdez}@unex.es

**Resumen**—En este artículo se presenta un análisis preliminar de un modelo de operador de mutación dirigida para problemas con codificación binaria y sin epistas. Esta versión del operador permite asociar una probabilidad de mutación a cada gen de cada individuo, proporcional a la influencia que ha tenido dicho gen sobre la calidad del individuo durante el proceso evolutivo. Estos valores de probabilidad, permiten a cada individuo realizar mutaciones de manera dirigida, con el objetivo de reducir el tiempo de convergencia del algoritmo.

El conjunto de experimentos realizado con el nuevo operador de mutación demuestra que el algoritmo genético converge a soluciones en etapas más tempranas del proceso evolutivo, en comparación con la mutación clásica. Se han llevado a cabo una serie de experimentos con un problema clásico de test, donde aplicando el nuevo operador de mutación dirigida, se consiguen buenos resultados. Aunque estos resultados son aún muy preliminares, esperamos poder continuar el estudio en problemas más complejos en el futuro, y mostrar así la utilidad de esta versión de la mutación dirigida en otros contextos.

## I. INTRODUCTION

Los algoritmos evolutivos [5] (AEs), son un conjunto de técnicas de optimización y búsqueda de soluciones basados en la teoría de la evolución de Charles Darwin. Inspirados en esta teoría, utilizan una población de individuos, soluciones candidatas al problema que pretende resolverse, que tratan de adaptarse mediante evolución al entorno para resolver el problema en cuestión.

Dentro de la familia de los AEs se encuentran los algoritmos genéticos [6] (AGs). Estos nos ofrecen técnicas robustas de búsqueda y optimización para la obtención de resultados en una gran variedad de problemas. Por ejemplo, son ampliamente utilizados en los problemas conocidos como “NP completos”, donde ofrecen la posibilidad de encontrar soluciones satisfactorias en tiempos razonables. En la actualidad

los AGs son ampliamente utilizados por la comunidad científica.

Un AG típico se compone de los siguientes elementos:

- Un individuo: es la representación de una posible solución al problema.
- Una población: compuesta por un conjunto de individuos.
- Una función de fitness: que permite evaluar la calidad de un individuo.
- Operadores genéticos: que permiten generar una nueva población a partir de la anterior (operador cruce, operador mutación y operador selección).
- Parámetros de control: que permiten controlar la ejecución del algoritmo.

Para maximizar la eficiencia de los AGs es posible modificar los parámetros y operadores genéticos anteriormente mencionados.

Entre los componentes del algoritmo, hay tres parámetros fácilmente ajustables que permiten modificar el proceso de búsqueda de soluciones: probabilidad de mutación ( $P_m$ ), probabilidad de cruce ( $P_c$ ) y tamaño de la población ( $T$ ). Son numerosos los estudios existentes que se centran en proponer heurísticas para optimizar dichos parámetros con la finalidad de obtener mejores resultados.

En este artículo se presenta una alternativa a uno de los operadores utilizados en el proceso de un AG, el operador de mutación. Está demostrado que este operador es necesario para garantizar la convergencia del algoritmo evolutivo. Su objetivo es la modificación del valor de un gen determinado, previamente seleccionado al azar, perteneciente un individuo. Este operador está contralado por el parámetro conocido como probabilidad de mutación, que determina cuándo se aplica dicha mutación.

La importancia del operador mutación ha sido estudiada ampliamente en la literatura, y ha quedado

demostrado que sin él no se garantiza la convergencia del algoritmo [9]. A pesar de todo, el proceso de convergencia puede ser lento, dependiendo de la dificultad del problema. Frecuentemente, esta dificultad implica el uso de cromosomas de tamaño grande, y el tamaño del cromosoma afecta a la eficacia del operador de mutación clásico, que selecciona al azar una posición a mutar: cuanto más largo es el cromosoma, más tiempo será necesario para poder mutar alguna posición concreta del mismo.

En este artículo se presenta una nueva implementación para el operador genético mutación, para problemas en los cuales no existe epistasis entre los genes que conforman el cromosoma de un individuo. Existe epistasis entre los genes de un individuo cuando la expresión de uno o más genes depende de la expresión de otro gen del mismo individuo. Esta interacción sucede cuando la modificación de un gen influye de manera directa sobre el valor en uno o varios genes diferentes del mismo individuo.

La nueva propuesta que se introduce en este trabajo, que como veremos más adelante es una variación de algunos modelos de mutación existente, pretende asociar una probabilidad de mutación a cada gen dentro del cromosoma del individuo. Esta probabilidad se debe ir actualizado con cada mutación sufrida y va a depender de la influencia que dicha mutación pueda tener sobre el valor del fitness global del individuo.

Los resultados presentados en este trabajo demuestran que es posible alcanzar mejores soluciones en un tiempo menor de cómputo, así como utilizando menores generaciones en el proceso evolutivo.

El resto del artículo se divide de la siguiente forma: en la Sección II se detalla un estado del arte de trabajos anteriores donde se aborda el problema de mutación dirigida, la Sección III se describe la metodología utilizada, los resultados de este trabajo se presentan en la Sección IV. Finalmente las conclusiones del mismo se abordan en la Sección V.

## II. ESTADO DEL ARTE

La modificación de los diferentes operadores de un AG es un campo ampliamente estudiado por la comunidad científica. Desde el inicio, los investigadores no han dejado de proponer mejoras para los operadores genéticos con la finalidad de obtener AGs que converjan a una solución de forma más rápida. En esta sección nos centraremos en el estudio de posibles mejoras del operador de mutación, fijándonos en particular en versiones del operador que permitan dirigir

su acción hacia zonas específicas del cromosoma que puedan ser de mayor interés.

Una de las primeras mejoras para el operador mutación que se propusieron fue dotar al AG de la capacidad de adaptar la probabilidad de mutación establecida [1], esta técnica es conocida como mutación adaptativa. La idea es simple pero efectiva. Dependiendo del valor de fitness obtenido por los individuos de la población en las diferentes generaciones, la probabilidad se adapta para permitir más o menos mutaciones, de esta manera cuando el fitness global de la población es malo, cuando el proceso de convergencia se estanca, el AG aumentará la probabilidad de mutación, con la esperanza de que estas mutaciones mejoren a los individuos, y viceversa, disminuirá la probabilidad de mutación cuando el fitness de los individuos sea buena para no degradar la calidad de la solución. Esta idea también ha sido aplicada con la probabilidad de cruce. Existen propuestas más avanzadas dentro de la mutación adaptativa, por ejemplo en [2] se propone un operador que modifica la probabilidad de mutación en función del fitness de los individuos de la población, utilizando para ello el algoritmo k-means. Otro enfoque muy utilizado dentro de la mutación adaptativa ha sido la modificación del AG para que en lugar de disponer de una probabilidad de mutación global, cada individuo cuente con una propia. Esta idea se ha codificado tradicionalmente con un gen más al principio del cromosoma y su cálculo se obtiene al generar un número aleatorio dentro de una distribución normal [3]. A lo largo de los años se han utilizado otro tipo de distribuciones de probabilidad, por ejemplo una distribución Levy [4], pero manteniendo la idea anteriormente descrita.

Entre las técnicas utilizadas para mejorar el operador genético de mutación se encuentra la que se conoce como mutación dirigida. Ésta, a diferencia de la mutación adaptativa, basa su funcionamiento en guiar al AG hacia mutaciones más beneficiosas, entendiendo como mutaciones más beneficiosas aquellas que hacen que el valor del fitness de un individuo mejore. En el artículo presentado por Dinabandhu Bhandari et al [7] se propone un operador de mutación que, dependiendo del valor de fitness obtenido en la generaciones anteriores, calcula un punto de mutación para los individuos que integran la población actual.

En el trabajo presentado por Bäck et al.[8] propone una idea novedosa dentro de la mutación adaptativa. Se asocia una probabilidad de mutación a cada uno



de los genes del cromosoma del individuo. Esta probabilidad es un valor aleatorio dentro de un rango. Utilizando esta idea como punto de partida, en este artículo exploramos otras posibilidades, haciendo una primera implementación de una idea similar.

La mutación dirigida que presentamos más adelante, asocia una probabilidad de mutación a cada uno de los genes que componen el cromosoma, en función a la influencia histórica que cada gen ha tenido sobre la mejora de la calidad del individuo, a lo largo del proceso evolutivo. A diferencia del trabajo propuesto en [8], esta propuesta tiene en cuenta cómo ha evolucionado cada individuo de la población, para tratar de guiarlo hacia mutaciones más beneficiosas. El operador que se propone dirige las mutaciones a genes concretos del cromosoma, que mejoren la calidad del individuo, pero en ningún momento modifica el valor de probabilidad de mutación del AG.

### III. PROPUESTA DEL NUEVO OPERADOR MUTACIÓN

En esta sección se describe en detalle el nuevo operador genético de mutación propuesto, al cual denominamos *mutación dirigida*, y que se considera en el contexto de problemas de codificación binaria sin epistasis. El objetivo es asociar un valor de probabilidad de mutación a cada gen del cromosoma, y utilizar estos valores de probabilidad en el proceso de mutación. Este nuevo modelo conlleva la utilización de un nuevo vector de probabilidades asociado a cada cromosoma, lo que implicará cambios en el operador de cruce. Estos cambios serán mínimos y solo se utilizan para mantener esta información actualizada en el proceso de cruce.

El nuevo operador de mutación dirigida asigna diferentes probabilidades de mutación a cada uno de los genes de cada individuo de la población, valores que dependerán de la influencia histórica que cada gen ha tenido en la mejora de ese individuo a lo largo del proceso evolutivo.

Para conocer en cada momento la influencia que cierto gen ha tenido sobre la calidad del individuo que lo contiene, es necesario disponer en la codificación del individuo de una nueva estructura capaz de almacenar dicha información. En nuestro caso se ha optado por utilizar un vector, denominado *vector de probabilidad de mutación* (VPM). La Figura 1 muestra un ejemplo gráfico del nuevo cromosoma.

El vector de probabilidades se encarga de almacenar la probabilidad de mutación asociada a cada gen

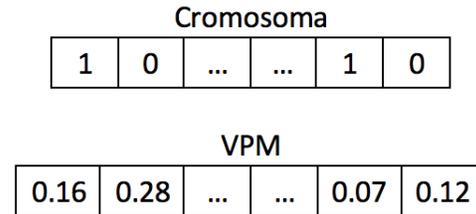


Figura 1. Ejemplo de codificación del VPM

del cromosoma (PMG). La suma de todas las probabilidades contenidas en el VPM debe ser siempre 1, ver figura 1, no pudiendo superar ni disminuir este valor en ningún momento del ciclo evolutivo del AG.

$$\sum_{i=1}^T PMG_i = 1 \quad (1)$$

donde  $T$  es el número de genes del cromosoma (Tamaño) y  $PMG_i$  es la probabilidad de mutación del gen  $i$ -ésimo.

La actualización del VPM es realizada cada vez que un individuo de la población sufre una mutación. Antes de comenzar a explicar en detalle cómo funciona el nuevo operador es importante indicar como se inicializan las PMG del VPM para cada individuo en el proceso de generación de la población inicial. Al generar la población inicial, aún no se tienen datos del histórico de evolución de la fitness, de ahí que todas las posiciones del vector VPM de cada individuo comienzan con la misma probabilidad, esta es calculada según la expresión 2

$$PMG = \frac{1}{T} \quad (2)$$

donde  $T$  es el tamaño del cromosoma

#### III-A. Mutación

Con el vector de probabilidad de mutación inicializado, los pasos a realizar por el nuevo operador de mutación, cada vez que queremos aplicar una mutación a un individuo, son los siguientes:

1. Comprobar si el individuo debe mutar, esta acción viene determinada por el parámetro probabilidad de mutación ( $P_m$ ), presente en la implementación clásica de cualquier AG.
2. Haciendo uso del método de selección conocido como *ruleta* sobre el VPM del individuo, se selecciona el gen que sufrirá la mutación. Esta técnica posibilita que cualquier gen pueda

ser seleccionado para sufrir una mutación, favoreciendo la selección de aquellos genes con un mayor índice de probabilidad -PMG- en el VPM.

3. Cálculo de la fitness del individuo antes de sufrir la mutación. Hay que recordar, que el proceso de mutación se aplica después del cruce, por lo que los individuos recién cruzados no disponen aún de valor de fitness.
4. Realizar la mutación del gen seleccionado en el paso anterior y cálculo del nuevo fitness del individuo.
5. Actualizar el VPM según el valor resultante, al comparar el fitness del individuo antes de sufrir la mutación y después. Para realizar esta operación se aumentará o disminuirá, una cantidad *alpha* (dependiendo de si la mutación mejoró o no al individuo) la probabilidad asociada a la posición del gen mutado, y proporcionalmente, se disminuirán o aumentará el resto de valores correspondientes al resto de los genes. La suma total de los valores del vector debe seguir siendo uno. Este valor *alpha* será a partir de ahora un nuevo parámetro del algoritmo.

### III-B. Cruce

El operador genético de cruce también sufre una modificación con respecto a su implementación clásica, debido a la necesidad de manejar correctamente los vectores de probabilidad de los individuos.

En el operador cruce clásico *one-point crossover* se genera una posición aleatoria del cromosoma que se utiliza para cruzar los dos padres intercambiando material genético en los hijos.

El nuevo operador cruce realiza la misma operación sobre los cromosomas, y además, repite ese mismo proceso con los PMGs de cada padre; pero dado que la suma de los PMGs resultantes de los nuevos individuos no tiene porqué ser 1, al finalizar el cruce es necesario realizar una normalización de estos valores -escalado para que la suma sea 1- para que la suma del nuevo VPM resultante de cada individuo hijo sea 1.

## IV. EXPERIMENTOS Y RESULTADOS

En esta sección se describen los experimentos que se han realizado para comparar el nuevo operador genético de mutación que se propone en este trabajo, con el operador clásico de mutación en problemas sin epistasis entre los genes de los individuos.

Para poder comparar ambos operadores de mutación se ha utilizado un problema bien conocido dentro de la literatura. El problema escogido ha sido el clásico *max-one*. Se trata de un problema de codificación binaria el cual ha sido ejecutado utilizando el operador clásico de mutación y el nuevo enfoque propuesto en este trabajo. La Tabla IV muestra los resultados de los diferentes experimentos que se han realizado. Como puede observarse, estamos particularmente interesados en conocer la utilidad del operador en problemas de tamaño grande: cuando el cromosoma del individuo tiene una longitud tal que son necesarias muchas generaciones para encontrar la solución. Así, hemos probado el operador en tamaños que van de 20 hasta 80 bits.

Para seleccionar un valor *alpha* adecuado para los experimentos, se ha realizado un estudio previo. Con un tamaño de cromosoma igual a 20 bits se han realizado 150 ejecuciones para cada uno de los valores del parámetro *alpha* que hemos querido probar. De esta manera hemos podido determinar el valor *alpha* que menos generaciones necesitaba para converger a la solución. Como se aprecia en Figura 2, que muestra los promedios para 150 ejecuciones de cada configuración, el valor de *alpha* que obtiene mejores resultados es 0.1.

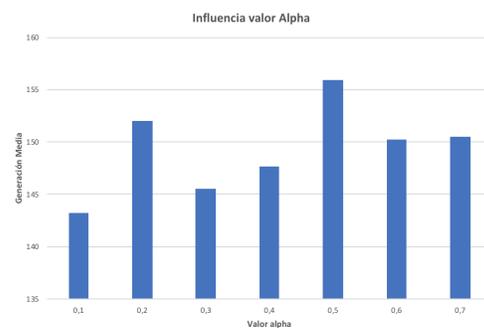


Figura 2. Resultado estudio valor, *Alpha*, cromosoma tamaño 20 bits

Una vez seleccionado el valor *alpha* adecuado, hemos procedido con los experimentos que se muestran en Tabla IV, de nuevo con 150 ejecuciones de cada configuración. La Figura 3 muestra la generación media que ha tardado el AG en converger a la solución para cada una de las combinaciones mostradas. Como se puede observar el operador de mutación dirigida toma menos generaciones en alcanzar la solución, son necesarias menos generaciones para obtener el mismo resultado que con el operador clásico. Como se aprecia en la gráfica la ventaja obtenida por



Experimento	AG	Tam. Población.	Tam. Cromosoma	Num. Generaciones	Prob. Mutación	Alpha
Ex1	C	10	20	20.000	0.01	-
Ex2	I	10	20	20.000	0.01	0.1
Ex3	C	10	40	20.000	0.01	-
Ex4	I	10	40	20.000	0.01	0.1
Ex5	C	10	60	20.000	0.01	-
Ex6	I	10	60	20.000	0.01	0.1
Ex7	C	10	80	20.000	0.01	-
Ex7	I	10	80	20.000	0.01	0.1

Cuadro I  
EXPERIMENTOS REALIZADOS

el nuevo operador respecto al clásico en cuanto al número de generaciones necesarias para obtener una solución aumenta con el tamaño del cromosoma de los individuos de la población. Cuanto el tamaño del individuo es mayor -la dificultad del problema es mayor- la diferencia entre la generación media necesaria para alcanzar solución es mayor entre ambas implementaciones, aportando un mejor rendimiento el operador de mutación dirigida.

La Figura 4 muestra el tiempo medio para alcanzar una solución por ambas implementaciones de los algoritmos. Al igual que sucede con las generaciones, el tiempo medio necesario para obtener la solución por el operador mutación dirigida es menor que la clásica, siendo la diferencia mayor cuanto mayor es el cromosoma del individuo.

Para tamaño de cromosomas superiores a 80 bits ambas implementaciones no siempre convergen a la solución. Aun así, el operador de mutación dirigida converge a la solución un número mayor de veces que el operador clásico (en las 150 ejecuciones realizadas). Para un tamaño de cromosoma igual a 120 bits el operador clásico ha convergido a la solución en 51 ocasiones mientras que el nuevo operador propuesto lo ha hecho 134.

Como decíamos anteriormente, lo aquí mostrado es un análisis preliminar de una variación del operador de *mutación dirigida*. En próximos trabajos pretendemos hacer una comparativa con alguno de los métodos de mutación más cercanos al aquí propuesto, y realizar una selección más adecuada de problemas de test, para estudiar con mayor detalle la potencialidad del nuevo operador. No obstante, estos resultados preliminares muestran el camino a seguir.

## V. CONCLUSIONES

Este artículo presenta un análisis preliminar de una nueva versión del operador de mutación adaptado a problemas en los que no existe epistasia. El objetivo de la propuesta es ayudar a determinar en cada momento las posiciones del cromosoma que más pueden

ayudar en la mejora de la calidad del individuo tras una mutación.

El nuevo operador asocia una probabilidad de mutación a cada gen del individuo, posición dentro del cromosoma, que es proporcional a la influencia histórica que ha tenido esa posición sobre la mejora de la calidad del individuo a lo largo del proceso evolutivo. Así, se utiliza un vector de probabilidades VPM, con una posición por cada gen que existe en el cromosoma PMG, para realizar mutaciones dirigidas sobre genes concretos que probablemente beneficiarán la calidad del individuo. Este vector de probabilidades es actualizado en cada proceso de mutación, con un valor que depende de la mejora (o empeoramiento) que la mutación produce en el nuevo individuo cuando se compara con el individuo sin mutación.

Utilizando el clásico problema max-one, de codificación binaria y sin epistasia entre los genes del individuo, hemos comparado el AG clásico con la nueva propuesta que utiliza mutación dirigida, con diferentes configuraciones del problema, variando el tamaño de las poblaciones, el tamaño de los individuos y la probabilidad de mutación del AG. En todos los casos la mutación dirigida ha permitido encontrar soluciones en menor número de generaciones, con una influencia que crece cuando lo hace el tamaño del cromosoma.

Esperamos poder extender este trabajo, con una comparativa más completa con otros operadores de mutación similares, y con un mayor número de problemas, tanto de codificación binaria como real, para entender mejor el impacto del nuevo operador de mutación propuesto.

## AGRADECIMIENTOS

Agradecemos el apoyo del Ministerio de Economía y Competitividad proyecto TIN2017-85727-C4-2,4-P, Junta de Extremadura, Consejería de Comercio y Economía, proyecto IB16035 a través del

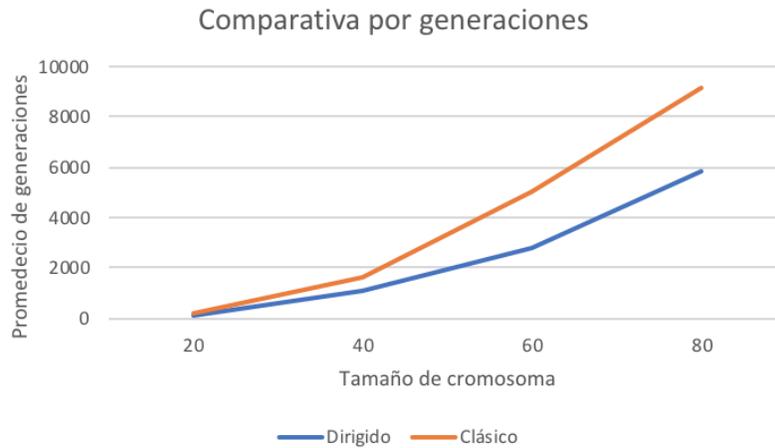


Figura 3. Resultados al comparar las dos implementaciones por número medio de generaciones necesarias para obtener una solución

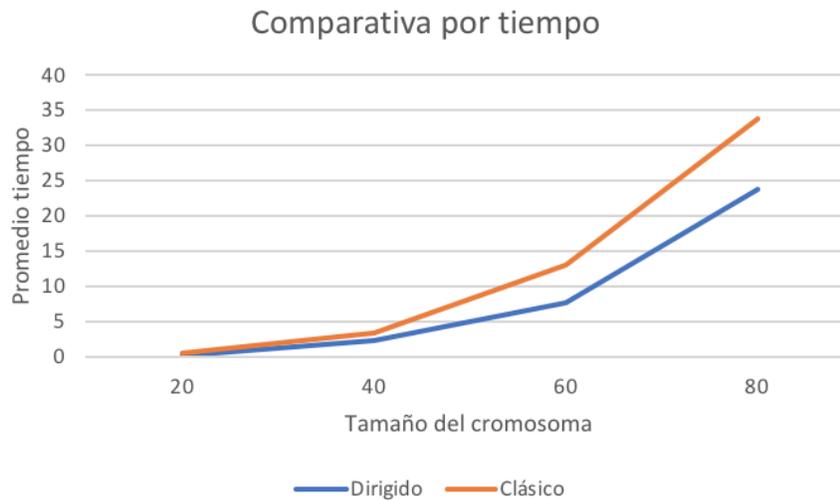


Figura 4. Resultados obtenidos al comparar las dos implementaciones por el tiempo medio necesario para obtener una solución.

Fondo Europeo de Desarrollo Regional, “Una manera de hacer Europa”.

#### REFERENCIAS

- [1] Srinivas, M., Patnaik, L. M. “Adaptive probabilities of crossover and mutation in genetic algorithms,” *IEEE Transactions on Systems, Man, and Cybernetics*, 24(4), 656-667, 1994.
- [2] Zhang, J., Chung, H. S. H., Lo, W. L. “Clustering-based adaptive crossover and mutation probabilities for genetic algorithms,” *IEEE Transactions on Evolutionary Computation*, 11(3), 326-335, 2007
- [3] Fogel, D. B., Atmar, J. W. “Comparing genetic operators with Gaussian mutations in simulated evolutionary processes using linear systems,” *Biological Cybernetics*, 63(2), 111-114, 1990.
- [4] Lee, C. Y., Yao, X. “Evolutionary programming using mutations based on the Lévy probability distribution,” *IEEE Transactions on Evolutionary Computation*, 8(1), 1-13, 2004
- [5] Back, T. “*Evolutionary algorithms in theory and practice: evolution strategies, evolutionary programming, genetic algorithms*,” Oxford university press. 1996
- [6] Goldberg, D. E., Holland, J. H. “Genetic algorithms and machine learning,” *Machine learning*, 3(2), 95-99, 1988.
- [7] Bhandari, D., Pal, N. R., Pal, S. K. “Directed mutation in genetic algorithms,” *Information Sciences*, 79(3-4), 251-270, 1994
- [8] Bäck, T. “Self-adaptation in genetic algorithms,” In *Proceedings of the first european conference on artificial life*, 263-271, MIT Press. 1992
- [9] Michalewicz, Z. “*Evolution strategies and other methods.*,” In *Genetic algorithms+ data structures= evolution programs* (pp. 159-177). Springer, Berlin, Heidelberg. 2016



# Choosing population sizes to enhance Brain Storm Optimization algorithms

Ricardo García-Ródenas, Luis Jiménez Linares, and Julio Alberto López-Gómez  
 {Ricardo.Garcia, Luis.Jimenez, JulioAlberto.Lopez}@uclm.es

**Abstract**—Nature-inspired algorithms (NIA) are a very powerful tool to solve plenty of complex science and engineering problems. In the last ten years, a new kind of NIA algorithms, so-called human-inspired algorithms, has arisen in optimization tasks obtaining promising results. In this paper, the effect of population size in Brain Storm Optimization algorithm (BSO) is studied with the purpose of choosing good enough population sizes which improve its performance. Moreover, it is also analyzed the possibility of using population samples instead of the whole population, studying its performance in terms of time and computational cost. To do that, hybrid functions of IEEE CEC competitions have been used as benchmark problems. The results show that twenty five individuals is a good enough population size in BSO algorithms while population sampling improves the performance of the algorithm.

**Index Terms**—Nature-inspired algorithms, Human-inspired algorithms, Brain storm optimization, Population size, Population sampling

## I. INTRODUCTION

Traditionally, complex optimization problems have required effective and sophisticated methods to deal with them. In this context, Nature-Inspired Algorithms (NIA) appeared in the 1960s. One of the main features of NIA algorithms is they take their knowledge, contents and procedures departing from nature. Thus, algorithms like Particle Swarm Optimization (PSO) [1], Genetic Algorithm (GA) [2] or Ant Colony Optimization (ACO) [3] among others, have been widely applied in operational research.

During the last ten years, there has been a change in the source of inspiration to build NIA algorithms. Nowadays there is a trend which tries to model the behaviour of humans in problem solving. Along this line, a new kind of NIA algorithms has appeared which is called Human-Inspired Algorithms (HIA). There are currently six HIA algorithms which are the following: Seeker Optimization Algorithm (SOA) [4], Imperialist Competitive Algorithm (ICA) [5], Social Emotional Optimization Algorithm (SEOA) [6], Teaching Learning-Based Optimization (TLBO) [7], Team Effectiveness Based Optimization (TEBO) [8] and Brain Storm Optimization algorithm (BSO) [9] which is the algorithm used in this paper.

This paper has two targets: On the one hand, it tries to choose good enough population sizes in Brain Storm Optimization

algorithm when it is applied to hybrid functions. On the other hand, it studies whether is better to use the whole population in the algorithm or only a sample of it, in terms of computational cost and quality of solutions.

The rest of the document is structured as follows: section 2 studies the related work in BSO algorithm. Section 3 describes BSO algorithm and ADMBSO algorithm, which is the version used in the experiments of this paper. Later, section 4 defines the experiments carried out and studies the results obtained and finally, section 5 introduces the conclusions about this work and some future works.

## II. RELATED WORK

To the best of our knowledge, there are 75 papers, 8 theses and 5 patents in total on the development and application of the BSO algorithm. The current research in BSO is concerned with three main research lines which are the following:

- **Study and analysis of the algorithm.** In this line, all studies about new brainstorming operators [10], modifications [11], clustering methods [12], parameters adjustment [13], hybridizations [14], etc are grouped.
- **Algorithm's variants.** New variants of brain storm algorithms are required to solve successfully different complex optimization problems like multimodal [15], hybrid or multiobjective problems [16], among others.
- **BSO applications.** There is a lack of BSO applications to real world problems, although there are many applications in fields like wireless sensor networks [17], multiple UAV formation flights [18], stock index forecasting [19] and economic dispatch [20].

## III. BRAIN STORM OPTIMIZATION ALGORITHMS

Brain Storm Optimization (BSO) algorithm is a human-inspired algorithm which was born in 2011 and developed by Shi [9]. This NIA algorithm is inspired by the human brainstorming process. In it, a group of people or brainstorming group proposes different ideas to solve a problem. Then, new ideas are generated from the existing ones in order to reach the optimum idea. The brainstorming process ends when an optimum idea has been achieved.

This way, brainstorming departs from a set of random initial solutions. After initialization, new ideas are generated departing from the existing ones through convergence and divergence operations. Convergence operation is focused on searching new solutions in a set of search areas where good solutions are found. Formally, these areas corresponds with

Ricardo García-Ródenas, Department of Mathematics at University of Castilla la Mancha, Spain

Luis Jiménez Linares, Department of Technology and Information Systems of University of Castilla la Mancha, Spain

Julio Alberto López Gómez, Department of Technology and Information Systems at University of Castilla la Mancha, Spain.

local minima in the objective function. To carry out convergence operation, cluster analysis techniques have been widely applied, using mainly the  $k$ -means algorithm. Moreover, divergence operation is in charge of building new solutions. In brainstorming, new solutions can be generated departing from one or more existing solutions. For simplicity, BSO algorithm considers only two possibilities: generating a new solution departing from one existing solution or two. The first option corresponds with local search in an optimization algorithm and the second is related to exploration. The kind of generation will be made using a set of probabilities. After BSO, different variants of the algorithm have appeared with the purpose of improving BSO capabilities and guaranteeing a good tradeoff between exploration and exploitation. In this paper, Advanced Discussion Mechanism based on Brain Storm Optimization Algorithm (ADMBSO) [11] is used instead of the original BSO. ADMBSO has been used since it is the most recent and standard version of BSO algorithm. In it, exploration is encouraged in the first iterations and exploitation in the last iterations. Moreover, ADMBSO adds different rules to generate new ideas in each epoch in intra and inter cluster generation. On the one hand, inter cluster generation will be possible in this algorithm building a new idea from two ideas in the same cluster. Briefly, this algorithm is shown in Algorithm 1.

#### IV. EXPERIMENTS

In this section, the two experiments carried out to choose good enough population sizes in Advanced BSO algorithm (ADMBSO) are described in detail.

##### A. Experiment 1: Choosing population size in BSO

The problem of choosing a good enough population size for a NIA algorithm is difficult to address. The reason is because it is generally problem-dependent and in general, the settings of one algorithmic parameter could be related to the settings of other algorithmic parameters, in terms of optimization performance. Besides, it depends on the particular version of BSO used, the dimensionality problem and the complexity of the search space. That is why, in this experiment, different population sizes widely applied in other algorithms have been tested over ADMBSO algorithm and over a set of concrete benchmark functions, in this case, hybrid functions from IEEE CEC conference competition.

In order to recommend good population sizes for BSO algorithms, the definition of robustness analysis proposed in [21] is taken. According to that, an optimization algorithm is robust if inequality

$$|f(x_{alg}^*) - f(x^*)| < \epsilon_{rel} \cdot |f(x^*)| + \epsilon_{abs} \quad (1)$$

holds, where  $x_{alg}^*$  is the best value reached by the algorithm,  $x^*$  is a global minimum of the objective function  $f$  (it is assumed, given) and  $\epsilon_{rel}$ ,  $\epsilon_{abs}$  are two parameters which control the accuracy of the algorithm.

Thus, different population sizes can be proposed and tested with different values of  $\epsilon_{abs}$  in order to detect if different

---

#### Algorithm 1 Advanced Discussion Mechanism based on BSO algorithm

---

```

1: POPULATION INITIALIZATION: Initialize  $n$  random solutions in population  $pop$ .
2: while Termination Condition is not satisfied do
3:    $P_{intra} = P_{low} + P_{high} \frac{N_{curgen}}{N_{maxgen}}$ 
4:    $P_{inter} = 1 - P_{intra}$ 
5:   /* Update  $\epsilon$  */
6:    $\epsilon(t) = \text{logsig} \left( \frac{\text{maxiter} - n_{iter}}{k} \right) * \text{random}(t)$ 
7:   POPULATION EVOLUTION: Generate  $n$  new ideas departing from the current population
8:   BEGIN Converging Operation
9:   Group  $pop$  in  $m$  clusters
10:  END Converging Operation
11:  for  $i = 1$  to  $\text{card}(pop)$  do
12:    BEGIN Diverging Operation
13:    if  $\text{rand}() < P_{intra}$  then
14:      /* Generate individuals from one cluster */
15:      if  $\text{rand}() < p_{ceni}$  then
16:        /* Add noise to center of the cluster */
17:         $c_{new}^i = c_{old}^i + \epsilon(t) * \text{random}(t)$ 
18:      else if  $\text{rand}() < p_{indi}$  then
19:        /*Combine two ideas from this cluster and add noise */
20:        Select  $x_{old1}$  and  $x_{old2}$ 
21:         $x_{new}^i = (x_{old1}^i - x_{old2}^i) * \text{random}(t)$ 
22:      else
23:        /*Add noise to a random idea*/
24:         $x_{new}^i = x_{old}^i + \epsilon(t) * \text{random}(t)$ 
25:      end if
26:    else
27:      /*Generate individuals from two clusters*/
28:      if  $\text{rand}() < p_{cenii}$  then
29:        /*Select two centroids  $c_{old1}$ ,  $c_{old2}$ , combine them and add noise*/
30:         $x_{old}^i = w_1 * c_{old1}^i + w_2 * c_{old2}^i$ 
31:         $x_{new}^i = (c_{old1}^i - c_{old2}^i) * \text{random}(t)$ 
32:      else if  $\text{rand}() < p_{indii}$  then
33:        /*Generate randomly an idea depart from two individuals of two clusters*/
34:        Select  $x_{old1}$  and  $x_{old2}$ 
35:         $x_{old}^i = w_1 * x_{old1}^i + w_2 * x_{old2}^i$ 
36:         $x_{new}^i = (x_{old1}^i - x_{old2}^i) * \text{random}(t)$ 
37:      else
38:        /* Generate randomly a new idea */
39:      end if
40:    end if
41:    END Diverging Operation
42:    REPLACE MECHANISM: If the new solution built is better than the current one, substitute it, otherwise, maintain the current solution
43:    /* Update Solution */
44:    if  $f(x_{new}) < f(x_{old})$  then
45:       $x_{old} = x_{new}$ 
46:    end if
47:  end for
48: end while

```

---



population sizes are capable of reaching determined levels of accuracy. Moreover, the convergence speeds of the same algorithm with different population sizes can also be compared using the expression proposed in [21] and shown in equation 2:

$$s = \frac{NFE_{pop1}}{NFE_{pop2}} \quad (2)$$

where  $s$  is the convergence speed ratio,  $NFE_{pop1}$  is the number of functions evaluations which the algorithm with the population size  $pop1$  needs to satisfy inequality (1) and  $NFE_{pop2}$  is the same using  $pop2$ . To do that, three  $\epsilon_{abs}$  values have been proposed in order to test the performance and robustness of different population sizes while  $\epsilon_{rel}$  has been fixed to  $10e^{-4}$  like in [21]. These values are  $\epsilon_{abs1} = 10e^{-1}$ ,  $\epsilon_{abs2} = 10e^{-3}$ ,  $\epsilon_{abs3} = 10e^{-5}$

Moreover, four population sizes have been tried in this experiment. Firstly, one hundred ideas has been taken as a reference value, since it is used in most of the articles published in BSO and cited here. After that, and following the fact that lower values are efficient in other metaheuristics like in PSO, other population sizes have been proposed. Thus,  $pop_{25}$  has twenty five ideas or individuals,  $pop_{50}$  has fifty ideas,  $pop_{75}$  has seventy five individuals and  $pop_{100}$  has one hundred ideas. The sample of benchmark functions consists of eight objective functions with thirty dimensions taken from IEEE CEC conference competitions. They are well-known optimization problems. In this paper, we have focused on hybrid functions, which are the most complex benchmarks in CEC competition. They are the following: rotated hybrid composition function 1, rotated hybrid composition function 1 with noise in fitness, rotated hybrid composition 2, rotated hybrid composition 2 with a narrow basin for the global optimum, rotated hybrid composition 3, rotated hybrid composition 3 with high condition number matrix, rotated hybrid composition function 4 and rotated hybrid composition function 4 without bounds. These problems are named as P1,P2,...,P8.

Then, ADMBSO algorithm has been executed for each population size using the parameters employed in [11]. The configuration is the following:  $m = 5$ ,  $P_{cen} = 0.7$ ,  $P_{ind} = 0.2$ ,  $P_{rnd} = 0.1$ ,  $P_{cens} = 0.7$ ,  $P_{low} = 0.2$ ,  $P_{high} = 0.7$ . The total number of function evaluations computed in each execution is 100000. Ten trials have been run for each population size in order to minimize the random effect in the experiment.

Average values of mean, maximum, minimum, variance and standard deviation have been obtained for each population size. The total time spent in all executions is reported too. These results are shown in table I. The minimum values for each measure are typed in bold. Thus, it is possible to see that  $pop_{25}$  needs less time than the rest of populations to achieve its results and it is the population which reaches the minimum values regarding the rest of population sizes in more test functions. Moreover, figure 1 shows the temporal cost of each population size for each problem. This way, it is possible to see that  $pop_{25}$  provides the best results regarding quality of solution and temporal cost.

Furthermore, regarding robustness analysis, table II shows the

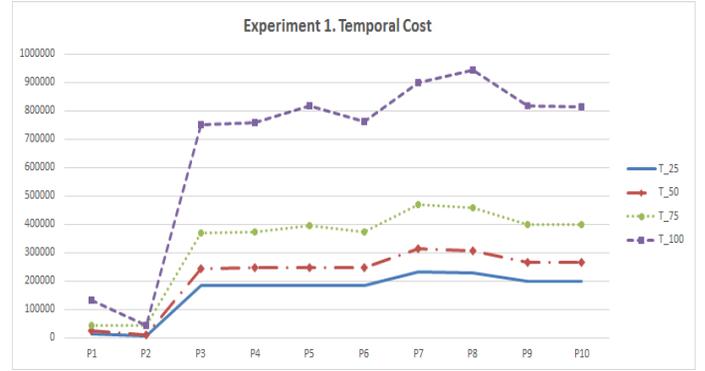


Fig. 1. Temporal Cost for different population sizes

convergence speed of different population sizes in comparison with the population of one hundred individuals (used in [11] and considered as reference). Note that problems 3 and 4 do not appear in this table because they did not achieve any robustness threshold. In this manner, when  $s$  values are less than 1, it means that the proposed configuration is better than  $pop_{100}$  taken as reference. If it is greater than 1, the performance of  $pop_{100}$  is better. The best rates are typed in bold. It is possible to conclude that all the sizes tested in this paper are better than  $p_{100}$  used in the most of articles published about BSO.

TABLE II  
ANALYSIS OF CONVERGENCE SPEED IN ADMBSO ALGORITHM

	s1	s2	s3
<b>P1_25</b>	<b>0,86</b>	-	-
<b>P1_50</b>	0,90	-	-
<b>P1_75</b>	0,93	-	-
<b>P2_25</b>	-	-	-
<b>P2_50</b>	<b>0,96</b>	-	-
<b>P2_75</b>	0,98	-	-
<b>P5_25</b>	<b>0,56</b>	-	-
<b>P5_50</b>	0,75	-	-
<b>P5_75</b>	0,99	-	-
<b>P6_25</b>	<b>0,59</b>	-	-
<b>P6_50</b>	1,04	-	-
<b>P6_75</b>	0,77	-	-
<b>P7_25</b>	<b>0,72</b>	0,95	-
<b>P7_50</b>	0,82	1,01	1,01
<b>P7_75</b>	1,09	<b>0,89</b>	<b>0,90</b>
<b>P8_25</b>	1,05	1,19	1,17
<b>P8_50</b>	<b>0,92</b>	<b>0,64</b>	<b>0,63</b>
<b>P8_75</b>	1,01	0,96	0,94

### B. Experiment 2: Population sampling in BSO

One solution to improve the quality of population could be to choose a sample of the population in the search process. It would imply a better initial population but include the problematic of choosing a good sample which combines good fitness values in the individuals chosen and good ideas diversity. Besides, the sampling process adds computational cost to the algorithm.

To do that, a multinomial probability distribution can be established according to the fitness values. This way, it will determine the probability of choosing an individual in the population according to the fitness values of the whole population.

TABLE I  
 ADMBSO STATISTICAL RESULTS FOR HYBRID CEC BENCHMARK FUNCTIONS

	Mean	Best	Worst	Variance	Std	Time
<b>P1_25</b>	<b>2,93E+02</b>	2,08E+02	1,55E+03	1,79E+04	1,33E+02	<b>1,82E+05</b>
P1_50	2,96E+02	2,21E+02	<b>1,10E+03</b>	<b>1,28E+04</b>	<b>1,13E+02</b>	2,44E+05
P1_75	3,57E+02	<b>1,66E+02</b>	1,06E+03	3,86E+04	1,96E+02	3,68E+05
P1_100	3,38E+02	2,21E+02	1,123E+03	1,54E+04	1,24E+02	7,50E+05
<b>P2_25</b>	<b>3,94E+02</b>	2,81E+02	1,54E+03	3,87E+04	1,96E+02	<b>1,84E+05</b>
P2_50	3,74E+02	2,40E+02	<b>1,21E+03</b>	3,68E+04	1,91E+02	2,46E+05
P2_75	3,76E+02	2,38E+02	1,54E+03	2,93E+04	1,71E+02	3,72E+05
P2_100	<b>3,58E+02</b>	<b>2,21E+02</b>	1,39E+03	<b>2,68E+04</b>	<b>1,64E+02</b>	7,59E+05
<b>P3_25</b>	<b>9,01E+02</b>	9,00E+02	1,45E+03	3,17E+02	1,7E+01	<b>1,84E+05</b>
P3_50	9,00E+02	9,00E+02	1,02E+03	<b>5,70E+01</b>	<b>7,59E+00</b>	2,46E+05
P3_75	8,74E+02	8,57E+02	1,41E+03	1,98E+03	4,45E+01	3,93E+05
P3_100	<b>8,68E+02</b>	<b>8,53E+02</b>	<b>9,06E+02</b>	3,21E+01	1,79E+01	8,17E+05
<b>P4_25</b>	<b>9,00E+02</b>	9,00E+02	<b>9,18E+02</b>	<b>5,39E+00</b>	<b>2,32E+00</b>	<b>1,84E+05</b>
P4_50	8,78E+02	8,66E+02	1,17E+03	2,73E+02	1,65E+01	2,46E+05
P4_75	<b>8,63E+02</b>	<b>8,47E+02</b>	1,39E+03	2,39E+02	4,89E+01	3,74E+05
P4_100	8,82E+02	8,66E+02	1,43E+03	8,33E+02	2,88E+01	7,63E+05
<b>P5_25</b>	<b>7,11E+02</b>	5,15E+02	1,48E+03	7,75E+ 04	2,78E+02	<b>2,33E+05</b>
P5_50	7,43E+02	<b>5,03E+02</b>	1,54E+03	8,17E+04	2,85E+02	3,12E+05
P5_75	8,91E+02	5,99E+02	<b>1,44E+03</b>	8,48E+04	2,91E+02	4,70E+05
P5_100	7,93E+02	5,33E+02	1,48E+03	<b>6,72E+04</b>	<b>2,59E+02</b>	8,99E+05
<b>P6_25</b>	<b>6,64E+02</b>	<b>5,38E+02</b>	2,48E+03	6,65E+04	2,57E+02	<b>2,29E+05</b>
P6_50	8,14E+02	6,69E+02	2,08E+03	<b>5,42E+04</b>	<b>2,32E+02</b>	3,07E+05
P6_75	7,54E+02	5,83E+02	1,91E+03	6,97E+04	2,64E+02	4,60E+05
P6_100	7,93E+02	6,07E+02	<b>1,87E+03</b>	6,90E+04	2,62E+02	9,42E+05
<b>P7_25</b>	<b>4,20E+02</b>	<b>2,29E+02</b>	1,57E+03	<b>1,37E+05</b>	<b>3,70E+02</b>	<b>1,97E+05</b>
P7_50	4,52E+02	2,40E+02	1,53E+03	1,57E+05	3,96E+02	2,64E+05
P7_75	5,25E+02	2,39E+02	1,52E+03	1,97E+05	4,44E+02	3,99E+05
P7_100	4,90E+02	2,39E+02	<b>1,52E+03</b>	1,72E+05	4,15E+02	8,17E+05
<b>P8_25</b>	<b>4,12E+02</b>	2,31E+02	1,65E+03	1,22E+05	3,49E+02	<b>1,98E+05</b>
P8_50	<b>4,03E+02</b>	<b>2,30E+02</b>	<b>1,48E+02</b>	1,31E+05	3,62E+02	2,66E+05
P8_75	4,17E+02	2,37E+02	1,51E+03	<b>1,15E+05</b>	<b>3,40E+02</b>	4,00E+05
P8_100	4,35E+02	2,44E+02	1,525E+03	1,28E+05	3,58E+02	8,15E+05

Thus, the probability of choosing an individual  $i$  is computed through equation.

$$P(i) = \frac{\frac{1}{f(i)}}{\sum_{j=1}^n \frac{1}{f(j)} + \epsilon} \quad (3)$$

where  $n$  is the population size,  $f(i)$  is the fitness value for individual  $i$  and  $\epsilon$  is a value near to zero to avoid to divide between 0. In previous experiment  $pop_{25}$  has been chosen as the best option in terms of population size. Now, ADMBSO algorithm has been executed using a population of one hundred individuals, but in this case, only twenty five individuals are selected to execute the algorithm. The selection mechanism is based on the multinomial probability distribution.

Now, ADMBSO algorithm with a sampled population of twenty five individuals have been executed under the same conditions as Experiment 1. Mean values of mean, minimum, maximum, variance and standard deviation as well as total time (in seconds) have been computed. These results are shown in table III. The results which improve the original results of  $pop_{25}$  are typed in bold.

With regard to the results, it can be noted this way of sampling population improves the original results of  $pop_{25}$ . Concretely, the major improvements are made in the last two problems which corresponds with the most difficult in CEC competitions (where  $pop_{25}$  did not improve the results of the rest of population sizes) and it is now the best configuration. Furthermore, it can be seen that the time is not improved in this case. To show that, figure 2 shows the temporal cost of

the population sizes made in experiment 1 in comparison with the temporal cost of population sampling.

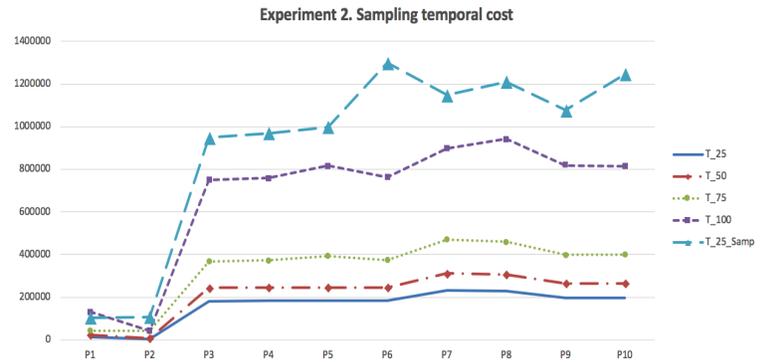


Fig. 2. Temporal Cost with original population sizes and sampling

Regarding robustness analysis, table IV shows the convergence speed ( $s$ ) of sampling population with respect to  $pop_{100}$  which was considered as reference. Once again, values which are equals or better than  $pop_{25}$  convergence speeds are typed in bold. The results show that sampling population increase the convergence speed of the algorithm in comparison with the original version.

## V. CONCLUSIONS AND FURTHER WORKS

In this article the problem of choosing good enough population sizes in BSO algorithms, has been carried out. To do



TABLE III  
STATISTICAL RESULT OF POPULATION SAMPLING

	Mean	Best	Worst	Variance	Std	Time
P1_25_Sam	2,91E+02	2,27E+02	9,11E+02	1,42E+04	1,19E+02	9,49E+05
P2_25_Sam	3,63E+02	2,81E+02	1,12E+02	1,46E+04	1,20E+02	9,68E+05
P3_25_Sam	9,00E+02	9,00E+02	1,29E+03	2,44E+02	1,56E+01	9,97E+05
P4_25_Sam	9,00E+02	9,00E+02	9,84E+01	7,51E+00	2,74E+00	1,29E+06
P5_25_Sam	7,14E+02	5,28E+02	1,56E+02	7,897E+04	2,81E+02	1,14E+06
P6_25_Sam	8,17E+02	6,78E+02	1,76E+03	4,51E+02	2,12E+02	1,21E+06
P7_25_Sam	3,76E+02	2,26E+01	1,64E+03	9,26E+04	3,04E+02	1,07E+06
P8_25_Sam	3,82E+02	2,63E+01	1,604E+02	9,84E+04	3,13E+02	1,24E+05

TABLE IV  
CONVERGENCE SPEED OF SAMPLING POPULATION

	s1	s2	s3
P1_Sam	0,55	0,88	0,86
P2_Sam	0	-	-
P3_Sam	0,87	-	-
P4_Sam	-	-	-
P7_Sam	0,53	-	-
P8_Sam	0,95	-	-
P9_Sam	0,70	0,66	0,66
P10_Sam	0,85	0,66	0,65

that, different population sizes have been defined in order to study the solutions achieved and the time spent for each size. After that, the best population size has been chosen and a strategy of sampling population has been carried out in order to study if this strategy improves the results of the original algorithm. The main conclusions reached are the following:

- Despite the fact that one hundred individuals have been widely used in the majority of articles published about BSO algorithms, it has been demonstrated that less individuals guarantee better results in terms of quality of solution in hybrid functions.
- Sampling population is a good solution to enhance the results of the original algorithm in terms of solutions achieved in the case of hybrid functions.
- Sampling population strategy speeds up the convergence speed of ADMBSO algorithm when it is applied over hybrid functions.

As future works, these experiments can be applied over different benchmark functions and new sampling strategies can be studied in order to reduce the temporal cost of the algorithm, as well as speeding up NIA algorithms through local search procedures in order to guarantee better robustness thresholds.

#### ACKNOWLEDGMENT

This research was supported by *Ministerio de Economía, Industria y Competitividad-FEDER* EU grants with number TRA2016-76914-C3-2-P

#### REFERENCES

- [1] Y. Shi and R. C. Eberhart, "A Modified Particle Swarm Optimizer," in *Proceedings of IEEE International Conference on Evolutionary Computation*. IEEE Computer Society, May 1998, pp. 69–73.
- [2] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, 1st ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989.

- [3] M. Dorigo, V. Maniezzo, and A. Coloni, "The ant system: Optimization by a colony of cooperating agents," *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS-PART B*, vol. 26, no. 1, pp. 29–41, 1996.
- [4] C. Dai, Y. Zhu, and W. Chen, "Seeker optimization algorithm," in *Computational Intelligence and Security*, Y. Wang, Y.-m. Cheung, and H. Liu, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, pp. 167–176.
- [5] E. Atashpaz-Gargari and C. Lucas, "Imperialist competitive algorithm: An algorithm for optimization inspired by imperialistic competition," *2007 IEEE Congress on Evolutionary Computation*, pp. 4661–4667, 2007.
- [6] Z. Cui, Z. Shi, and J. Zeng, "Using social emotional optimization algorithm to direct orbits of chaotic systems," in *Swarm, Evolutionary, and Memetic Computing*, B. K. Panigrahi, S. Das, P. N. Suganthan, and S. S. Dash, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, pp. 389–395.
- [7] R. Rao, V. Savsani, and D. Vakharia, "Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems," *Computer-Aided Design*, vol. 43, no. 3, pp. 303 – 315, 2011.
- [8] X. Feng, M. Ji, Z. Li, X. Qu, and B. Liu, "Team effectiveness based optimization," in *2017 IEEE Congress on Evolutionary Computation (CEC)*, June 2017, pp. 2248–2257.
- [9] Y. Shi, "Brain storm optimization algorithm," in *Advances in Swarm Intelligence*, Y. Tan, Y. Shi, Y. Chai, and G. Wang, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, pp. 303–309.
- [10] D. Zhou, Y. Shi, and S. Cheng, "Brain storm optimization algorithm with modified step-size and individual generation," in *Advances in Swarm Intelligence*, Y. Tan, Y. Shi, and Z. Ji, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 243–252.
- [11] Y. Yang, Y. Shi, and S. Xia, "Advanced discussion mechanism-based brain storm optimization algorithm," vol. 19, 10 2015.
- [12] J. Chen, Y. Xie, and J. Ni, "Brain storm optimization model based on uncertainty information," in *2014 Tenth International Conference on Computational Intelligence and Security*, Nov 2014, pp. 99–103.
- [13] Z. Zhan, W. Chen, Y. Lin, Y. Gong, Y. Li, and J. Zhang, "Parameter investigation in brain storm optimization," in *2013 IEEE Symposium on Swarm Intelligence (SIS)*, April 2013, pp. 103–110.
- [14] R. García-Ródenas, L. J. Linares, and J. A. López-Gómez, "A cooperative brain storm optimization algorithm," in *2017 IEEE Congress on Evolutionary Computation (CEC)*, June 2017, pp. 838–845.
- [15] X. Guo, Y. Wu, and L. Xie, "Modified brain storm optimization algorithm for multimodal optimization," in *Advances in Swarm Intelligence*, Y. Tan, Y. Shi, and C. A. C. Coello, Eds. Cham: Springer International Publishing, 2014, pp. 340–351.
- [16] X. Guo, Y. Wu, L. Xie, S. Cheng, and J. Xin, "An adaptive brain storm optimization algorithm for multiobjective optimization problems," in *Advances in Swarm and Computational Intelligence*, Y. Tan, Y. Shi, F. Buarque, A. Gelbukh, S. Das, and A. Engelbrecht, Eds. Cham: Springer International Publishing, 2015, pp. 365–372.
- [17] R. Ramadan and A. Khedr, "Brain storming algorithm for coverage and connectivity problem in wireless sensor network," 04 2016.
- [18] H. Qiu, H. Duan, and Y. Shi, "A decoupling receding horizon search approach to agent routing and optical sensor tasking based on brain storm optimization," *Optik - International Journal for Light and Electron Optics*, vol. 126, no. 7, pp. 690 – 696, 2015.
- [19] J. Wang, R. Hou, C. Wang, and L. Shen, "Improved v -support vector regression model based on variable selection and brain storm optimization for stock price forecasting," *Applied Soft Computing*, vol. 49, pp. 164 – 178, 2016.



- [20] K. R. Ramanand, K. R. Krishnanand, B. K. Panigrahi, and M. K. Mallick, "Brain storming incorporated teaching-learning-based algorithm with application to electric power dispatch," in *Swarm, Evolutionary, and Memetic Computing*, B. K. Panigrahi, S. Das, P. N. Suganthan, and P. K. Nanda, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 476–483.
- [21] F. Kang, J. Li, and Z. Ma, "Rosenbrock artificial bee colony algorithm for accurate global optimization of numerical functions," *Information Sciences*, vol. 181, no. 16, pp. 3508 – 3531, 2011.



# Distance-based Exponential Probability Models for Constrained Combinatorial Problems\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Josu Ceberio, Alexander Mendiburu  
University of the Basque Country UPV/EHU  
Donostia, Spain  
josu.ceberio@ehu.eus

Jose A. Lozano  
University of the Basque Country UPV/EHU  
Basque Center for Applied Mathematics (BCAM)  
Bilbao, Spain

**Abstract**—Estimation of Distribution Algorithms (EDAs) have already demonstrated their utility when solving a broad range of combinatorial problems. However, there is still room for methodological improvement when approaching problems with constraints. The great majority of works in the literature implement repairing or penalty schemes, or use ad-hoc sampling methods in order to guarantee the feasibility of solutions. In any of the previous cases, the behavior of the EDA is somehow denaturalized, since the sampled set does not follow the probability distribution estimated at that step. In this work, we present a general method to approach constrained combinatorial optimization problems by means of EDAs. This consists of developing distance-based exponential probability models defined exclusively on the set of feasible solutions. In order to illustrate this procedure, we take the 2-partition balanced Graph Partitioning Problem as a case of study, and design efficient learning and sampling methods to use distance-based exponential probability models in EDAs.

**Index Terms**—Constraint, estimation of distribution algorithm, distance-based exponential model, Graph Partitioning Problem



**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

JOSÉ RIQUELME

ALICIA TRONCOSO

SALVADOR GARCÍA





**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 1:  
MODELOS PREDICTIVOS







# Identifying ecosystem patterns from time series of anchovy (*Engraulis ringens*) and sardine (*Sardinops Sagax*) landings in northern Chile

1<sup>st</sup> Francisco Plaza  
Unidad de Auditoría y Control  
Instituto de Fomento Pesquero  
Valparaíso, Chile  
francisco.plaza.vega@ifop.cl

2<sup>nd</sup> Rodrigo Salas  
Escuela de Ingeniería Biomédica  
Universidad de Valparaíso  
Valparaíso, Chile  
rodrigo.salas@uv.cl

3<sup>rd</sup> Eleuterio Yáñez  
Escuela de Ciencias del Mar  
Pontificia Universidad Católica de Valparaíso  
Valparaíso, Chile  
eleuterio.yanez@pucv.cl

**Abstract**—This work presents a Knowledge Discovery from Data (KDD) approach in time series pattern identification for anchovy and sardine monthly fishery-biological data in northern Chile. Time series, multivariate analysis and data mining techniques, along with technical literature review for results validation are implemented. This approach, achieved an integration between variables, identifying relevant patterns, associated with fisheries abundance fluctuations and strong association with environmental changes such as El Niño and long-term cold-warm regimes between them, establishing predominant time-periods. The latter, establishes groundwork for studying underlying functional relationships that could reduce gaps in the national fisheries research and management policies.

**Index Terms**—Anchovy, Sardine, Ecosystem, Patterns, Data Mining, Time Series, Knowledge Discovery from Data

## I. INTRODUCTION

The Chile-Peru Current System (CHPCS) is a very productive marine system due to nutrient transport by large-scale horizontal advection and persistent coastal upwelling. In Chile the average annual landing in the last 30 years is 4.8 million tons and the pelagic resources of the northern zone (18°21'S-24°S) represent 40% ([2]). In this area the fishery is successively based on anchovy (*Engraulis ringens*) and sardine (*Sardinops sagax*), with notable changes associated with fishing effort and fluctuations in the environment ([3]).

Ocean-climate changes alter marine ecosystems at various scales, in fact, [3] propose an integrative conceptual model of the main local to large-scale phenomena involved in northern Chile. On the intra-seasonal scale, coastal trapped waves are mainly responsible for most of the variability of sea surface temperature and currents on the continental shelf and slope of the CHPCS. On the interannual scale, changes in atmospheric and oceanographic conditions are mainly associated with the El Niño Southern Oscillation (ENSO) phenomenon. Interdecadal long-term regime shifts (warm or cold), would influence the reorganization of marine communities and trophodynamic relationships, inducing changes in dominant species. Thus, the link between the variation of anchovy abundance and environmental changes at different spatio-temporal scales opens the possibility for predicting fluctuations in landings in

the short, medium, and long term, one of the main objectives of fisheries management ([4]; [5]). Therefore, the main objective for this work is to identify patterns of interaction between those variables in northern Chile.

## II. MATERIALS AND METHODS

### A. Data

The study analyzes monthly data considering local and global environmental variables and fishing variables from 1963-2011 in northern Chile (18°21'S-24°S and from the coast until 73°O). This area is where industrial purse seine fleet operates in northern Chile. Table I summarize all considered variables.

TABLE I  
SUMMARY OF ANALYZED VARIABLES

Type	Variable	Description
Local	SST	Sea Surface Temperature from Antofagasta coastal oceanographic station
	TI	Turbulence Index from Antofagasta coastal oceanographic station
	MSL	Mean Sea Level from Antofagasta coastal oceanographic station
Global	MEI	Multivariate ENSO Index
	PDO	Pacific Decadal Oscillation index
	N12	Climatic Index in the Niño12 area
	N34	Climatic Index in the Niño34 area
	SOI	Southern Oscillation Index
Fisheries	CTI	Cold Tongue Index
	VANC	% days per month of anchovy fishing prohibition (fisheries ban)
	VSAR	% days per month of sardine fishing prohibition (fisheries ban)
	LANC	Anchovy landings in northern Chile
	LSAR	Sardine landings in northern Chile

### B. General procedure

For this study, a similar approach to [6] is considered, involving as a first step an inspection of the multivariate time series, using signal decomposition (trend, seasonality and noise), then Principal Components Analysis is performed to reduce dimensionality and to discover preliminary patterns (which are contrasted with field literature). Finally, as a third step these patterns are grouped, using k-means clustering, in order to obtain different ecosystem periods, which allows to identify changing trends (increases or decreases) of anchovy and sardine landings, associated to environmental conditions. Integrated graphical representations are then implemented to show discovered patterns.

### III. RESULTS AND DISCUSSION

Figure 1 shows the additive decomposition performed on the 4 PCs, showing the trend, seasonality and irregular component.

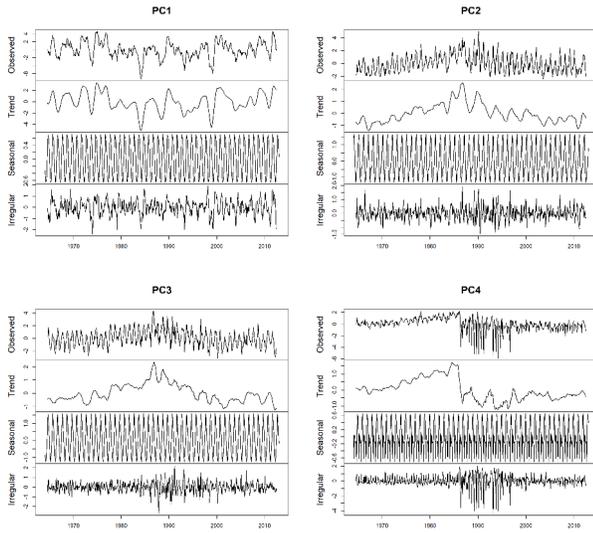


Fig. 1. Decomposition of the selected PCA components.

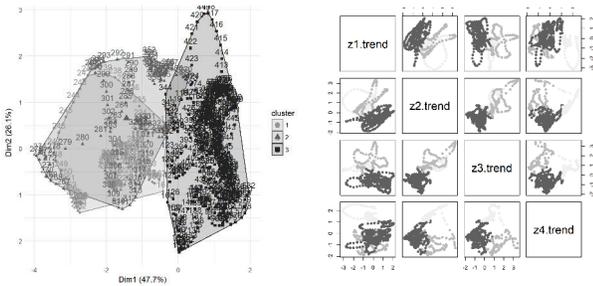


Fig. 2. Clustering performance and results. Representation of clusters centroids (left), classification of the principal components (right).

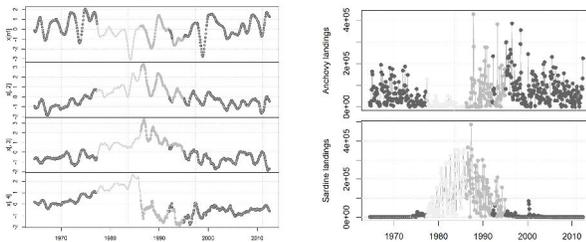


Fig. 3. Cluster classification applied to data. Cluster classification of PCA selected components (left), Cluster classification of anchovy and sardine landings time series (LANC and LSAR)(right).

In order to address the problem, a series of research questions were established to guide the analysis. To summarize the results obtained in this study, the answer for each research question is presented as follows:

- 1) *what is the relationship between the time series between sardine and anchovy?*. Results show an alternance between anchovy and sardine time series. The latter can be observed in both the time series of each fishery and in the results obtained from the clustering process (Fig. 3, having an anchovy period, then a transition period, followed by a sardine period, and finally an anchovy period, respectively.
- 2) *what is the relationship between environmental variables and the anchovy-sardine?*. As discussed before, the first 4 components from the PCA have higher correlation with environmental variables. Also, the clustering process identified 3 clusters which can be related to environmental long-term cold-warm-cold periods(Fig. 2). Furthermore, those long-term periods are related with anchovy and sardine landings presence or absence. The underlying processes that describe functional relationships between particular environmental variables and anchovy and sardine behavior are still being discussed among the scientific community. However, this study proposes a more integrated scope, considering the ecosystem as a whole.
- 3) *Are there any procedures that allow to identify patterns?*. A process of mixing three well-known techniques (time series decomposition, principal components analysis and clustering) was successfully implemented in order to identify ecosystemic patterns.
- 4) *Are there identifiable patterns in the time series of anchovy, sardine, and environmental variables?*. Four clear periods could be identified, from 1963-1977, 1977-1986, 1986-1995 and 1995-2011, having an anchovy period, then a transition period, followed by a sardine period, and finally an anchovy period, respectively (Fig. 3).

#### ACKNOWLEDGMENT

This paper is presented as an overview of the work done by [1].

#### REFERENCES

#### REFERENCES

- [1] F. Plaza, R. Salas, and E. Yáñez, "Identifying ecosystem patterns from time series of anchovy (*Engraulis ringens*) and sardine (*Sardinops sagax*) landings in northern Chile," *Journal of Statistical Computation and Simulation*, vol.88(10), pp. 1863–1881.
- [2] SERNAPESCA. Anuarios Estadísticos de Pesca. Servicio Nacional de Pesca y Acuicultura, Chile; 1950-2012.
- [3] Yáñez E, Hormazábal S, Silva C, et al. Coupling between the environment and the pelagic resources exploited off northern Chile: ecosystem indicators and a conceptual model. *Latin American journal of aquatic research*. 2008 00; 36: 159–181.
- [4] Zhou S, Smith ADM, Punt AE, et al. Ecosystem-based fisheries management requires a change to the selective fishing philosophy. *Proceedings of the National Academy of Sciences*. 2010;107(21):9485–9489.
- [5] Chavez FP, Ryan J, Lluch-Cota SE, et al. From anchovies to sardines and back: multidecadal change in the pacific ocean. *Science*. 2003; 299(5604): 217–221.
- [6] Fayyad U, Pietetsky-Shapiro G, Smyth P. From Data Mining to Knowledge Discovery in Databases. *AI Magazine*. 1996; 3(17): 37–54.



# Análisis Big Data para la Respuesta a la Demanda en el Mercado Eléctrico

José Antonio Fábregas,  
José María Luna-Romera  
and José C. Riquelme Santos  
Lenguajes y Sistemas Informáticos  
Universidad de Sevilla  
Sevilla, España

Ángel Arcos-Vargas  
Organización Industrial y Gestión de Empresas  
Universidad de Sevilla  
Sevilla, España

Javier Tejedor Aguilera  
Endesa S.A.  
Madrid, España

**Abstract**—El modelo de negocio tradicional de las compañías energéticas está cambiando los últimos años. La introducción de los contadores inteligentes ha conllevado un aumento exponencial del volumen de datos disponibles, y su análisis puede ayudar a encontrar patrones de consumo entre los clientes eléctricos para reducir costes y proteger el medioambiente. Las centrales generan energía eléctrica para poder cubrir los picos de consumo en momentos puntuales. Un conjunto de técnicas denominadas "demand response" intenta dar solución a este problema usando propuestas de inteligencia artificial. En este documento se propone una metodología para el procesado de los grandes volúmenes de datos como los que generan los contadores inteligentes. Tanto para el preprocesado como para la optimización y realización de este análisis se utilizan técnicas big data. En concreto, una versión distribuida del algoritmo k-means y de varios índices de validación interna de clustering para big data en Spark. Los datos de origen corresponden los consumos de clientes eléctricos de Cataluña durante el año 2016. El análisis de estos consumidores realizado en este trabajo ayuda a su caracterización. Este mayor conocimiento sobre los hábitos de consumos y tipos de clientes, puede facilitar a las compañías eléctricas la labor.

**Index Terms**—Big data, respuesta a la demanda, clustering, contadores inteligentes, consumo eléctrico

## I. INTRODUCCIÓN

Durante la mayor parte del siglo XX, la relación entre los usuarios de electricidad y las empresas de distribución se mantuvo sin cambios. No se eligieron proveedores y, por lo tanto, no había necesidad de tratar a los consumidores como clientes. Sin embargo, la desregulación, la agenda verde y los continuos saltos tecnológicos han cambiado esta relación. Nuevas limitaciones como la seguridad del suministro, la competitividad y la sostenibilidad son los tres ejes prioritarios para cambiar el modelo energético actual, que pueden lograrse mediante objetivos como la reducción de las emisiones y la mejora de la generación de energía renovable y la eficiencia energética.

Una herramienta esencial en este nuevo modelo son los llamados "contadores inteligentes", que no deben entenderse sólo como dispositivos que miden el consumo sino

como verdaderos sensores para una red eléctrica. Estos sensores facilitan una red altamente flexible y adaptable que integra de forma inteligente las acciones de los usuarios que se conectan a ella para conseguir un suministro eficiente, seguro y sostenible.

Uno de los principales problemas del sector eléctrico es la necesidad de disponer de capacidad de generación y de una red sobredimensionada para cubrir los picos de alto consumo de los clientes en determinados momentos. Sin embargo, existen soluciones basadas en la adaptación de la demanda a la energía disponible en lugar de aumentar la oferta para satisfacer la demanda. Esto se denomina "Respuesta a la Demanda" y su objetivo es cambiar los hábitos de consumo de electricidad de los clientes en respuesta a los cambios en los precios del suministro. El principal inconveniente es el gran volumen de información disponible en estas redes, ya que sólo puede manejarse con técnicas big data.

Nuestra propuesta se basa en el procesado de estos grandes conjuntos de datos de manera distribuida y paralela. En particular, la aplicación de técnicas de minería de datos para comprender mejor los patrones de consumo de los clientes. Por un lado, haremos uso de HDFS [1] para el almacenamiento de datos distribuido. Mientras que el procesado lo realizaremos con Spark [2], una plataforma de computación distribuida y paralela. En concreto, utilizaremos la implementación del algoritmo k-means de la librería MLlib [3] de Spark, así como cuatro índices de validación de clustering para big data [4]. Este estudio podría ayudar a la planificación de las conexiones de las fuentes de energía renovables a la red, con un doble objetivo: la reducción de precios y la sostenibilidad medioambiental.

La estructura de este artículo es la siguiente. En la sección II se describen los trabajos relacionados. En la sección III se detallan las características del dataset. En la sección IV se muestran los resultados de los experimentos realizados para preprocesar los datos y aplicar técnicas de clustering. Para finalizar, en la sección V se presentan las conclusiones de la investigación realizada.

## II. TRABAJO RELACIONADOS

La irregularidad de la demanda de electricidad es uno de los principales problemas del sector. Esto se debe a que las compañías eléctricas deben tener tanto una capacidad de generación sobredimensionada, como redundancia de la red para hacer frente a grandes cantidades de demanda que sólo se requieren unas pocas horas al año. Normalmente, se establece un umbral del 20% para la generación de electricidad latente, que debe cubrir aproximadamente el 5% del tiempo de servicio de la red (pico de demanda) [5]. Algunos de los recursos para resolver este problema necesitan la implicación de los usuarios. Estas soluciones se estudian bajo el nombre de 'respuesta a la demanda' (Demand Response DR) [6]. En contraste con las ideas convencionales de aumentar la oferta para satisfacer la demanda, las soluciones apuntan a satisfacerla con la energía disponible.

El objetivo es cambiar las pautas de consumo de energía de los clientes en respuesta a los cambios en los precios ofrecidos. Esto permitirá a las compañías eléctricas gestionar mejor la demanda con un mejor ajuste de las predicciones y una reducción del coste de la energía para los clientes. Existen múltiples iniciativas de posibles esquemas de fijación de precios, que en algunos casos incluso mantienen los beneficios para las empresas proveedoras [7]. Una de las principales ventajas de la respuesta a la demanda es ofrecer una opción sostenible con una generación de energía más volátil. Sobre todo en España, donde existe una alta presencia de fuentes de generación renovables. Para implementar los mecanismos de respuesta a la demanda, las redes eléctricas deben evolucionar a una infraestructura que permita el flujo de información entre los diferentes participantes del sistema eléctrico. En este campo es donde los grandes datos se convierten en una tecnología esencial para analizar este flujo de información y convertirlo en conocimiento útil.

Estos datos de consumo de los clientes, obtenidos mediante contadores inteligentes, no son sino múltiples series temporales. El análisis de series temporales puede entenderse como una secuencia de valores observados a lo largo del tiempo y ordenados cronológicamente [8]. Como el tiempo es una variable continua, las muestras se registran en puntos sucesivos igualmente espaciados. Por lo tanto, las series temporales son una secuencia de datos de tiempo discreto.

En el contexto de la minería de datos de series temporales, el principal desafío es cómo representar los datos. El enfoque más común es transformar las series temporales en otro ámbito para la reducción de la dimensionalidad y desarrollar un mecanismo de indexación. La medida de la similitud entre las sub-secuencias de series temporales y la segmentación son las dos tareas principales en la minería de series temporales que corresponden con las tareas clásicas de la minería de datos. El uso cada vez mayor de datos de series cronológicas ha dado lugar a una

gran cantidad de intentos de investigación y desarrollo en el campo de la minería de datos [9].

En este trabajo nos centraremos en el clustering, un método de minería de datos para agrupar instancias no etiquetadas de conjuntos de datos. La idea es que las instancias recogidas en un mismo grupo tendrán un comportamiento similar [10]. El clustering de series temporales surge como un enfoque útil para minar patrones comunes a partir de datos dependientes del tiempo [11] que se caracterizan por tener una alta dimensionalidad y un gran tamaño.

Centrándonos en el clustering a partir de datos de consumo de energía, son muchas las propuestas enmarcadas en este campo: En [12] se presenta el efecto de las medidas de similitud en la aplicación de la agrupación para descubrir los patrones energéticos de los edificios. Para obtener perfiles de carga típicos de los clientes, en [13] se propone un índice de estabilidad para elegir el algoritmo de agrupamiento que mejor se adapte a este problema de reconocimiento de patrones. Además, se propone otro índice de prioridad (basado en el índice de estabilidad) para determinar el rango de prioridad de los agrupamientos. En [14] desarrolla una técnica de clustering de particiones para extraer información útil de los precios de la electricidad. Mientras que en [15] se usan técnicas de clustering con el objetivo de agrupar y etiquetar las muestras de un conjunto de datos para pronosticar el comportamiento de las series temporales basadas en la similitud de las secuencias de patrones.

En relación a la gestión inteligente de la demanda de electricidad, en [16] los autores proponen un Virtual Power Player como gestor para satisfacer la demanda y reserva de energía eléctrica requerida. En [17] se presenta un análisis de los datos de los contadores inteligentes de los clientes para comprender mejor la demanda máxima y las principales fuentes de variabilidad en su comportamiento.

Además de los métodos clásicos de gestión de datos, el enfoque de big data ha surgido recientemente debido a la disponibilidad de una gran cantidad de datos, sistemas de ficheros distribuidos, y potentes motores de procesamiento distribuido. Esto ha propiciado que muchos de los algoritmos de minería de datos se hayan adaptado al entorno de big data, como por ejemplo los algoritmos de clustering. En cuanto al campo del consumo de energía, en la actualidad han surgido varias grandes soluciones de datos, como las optimizaciones de redes inteligentes en [18] y los patrones de consumo energético en [19].

## III. CARACTERÍSTICAS DEL DATASET

Los datos originales se encuentran almacenados en 34 tablas, divididas en cientos de archivos CSV. Estas tablas contienen una amplia información sobre consumos, tarifas, contadores, datos geográficos o personales de consumidores eléctricos de Endesa en Cataluña entre 2010 y 2016 para un tamaño total de 1,8 TB.



Los clientes en los que centramos este estudio son aquellos que poseen tarifas 2.0A y 20DHA. Ambas del mercado libre de Endesa para potencias contratadas menores a 10kW, donde se encuentran inmensa mayoría de hogares y pequeños locales. La tarifa 2.0A mantiene un precio fijo durante todo el año, mientras que la 20DHA tiene discriminación horaria de dos periodos. En esta última, los periodos punta y valle marcan dos precios distintos según la hora en la que se consuma la energía: punta de 12h a 22h en invierno y de 13h a 23h en verano; valle de 22h a 12h en invierno y de 23h a 13h en verano.

En la Tabla Ia se observa la distribución de los clientes según su tarifa. Debido a la gran variedad de potencias contratadas, La Tabla Ib muestra una distribución de los clientes por cada rango de potencia. Estos rangos están basados en los valores estándar de potencia que actualmente pueden contratarse al tener contadores inteligentes.

TABLE I: Distribución de clientes

(a) Por tarifa contratada		(b) Por potencia contratada	
Tarifa	Clientes	Potencia(kW)	Clientes
2.0A	102,123	[0.1-2.3)	8,972
2DHA	6,614	[2.3-3.45)	21,969
		[3.45-4.60)	38,578
		[4.60-5.75)	22,328
		[5.75-6.90)	8,772
		[6.90-8.05)	3,134
		[8.05-9.20)	4,946
		[9.20-10.0)	82

#### IV. ANÁLISIS REALIZADOS

En esta sección se presentan los resultados de los análisis realizados. En el apartado IV-A se detalla el procesado de los datos. En el apartado IV-B se analizan cuatro índices de validación de clustering obtener el  $k$  óptimo. En el apartado IV-C se muestran los clusters obtenidos con el algoritmo  $k$ -means. Por último, en el apartado IV-D se realiza una evaluación de los resultados.

Para la realización de los experimentos se han utilizado los siguientes entornos:

- Cluster propio: 72 procesadores Intel Xeon E7-4820, 128 GB RAM y 8 TB de almacenamiento.
- Cluster de EMR (Elastic Map Reduce) de AWS: cinco instancias de m3.2xlarge con 16 procesadores Intel Xeon E5-2670 v2 (Ivy Bridge), 30 GB RAM y 2 SSDs DE 80 GB cada una.

##### A. Procesado de datos

El primer objetivo es conseguir un conjunto de datos que tenga sentido minar. Primero, almacenaremos la gran cantidad de datos de los que disponemos en un sistema de ficheros distribuido (HDFS) configurado en nuestro cluster. Para reducir el tamaño de los datos, los ficheros CSV se pasan a Parquet, un formato de datos orientado a columnas que los comprime y codifica. Una vez almacenados y formateados, todo el procesamiento de estos datos se

realiza de forma distribuida y paralela con Spark. Debido a que estos datos también se procesarán con herramientas online de Amazon Web Service, se almacenan además en el S3, el sistema de almacenamiento en línea de Amazon. Posteriormente se estudian y seleccionan los atributos necesarios para construir un primer dataset. Las tablas procesadas se muestran a continuación (Tabla II):

TABLE II: Tablas procesadas

Tabla	Elementos (millones)	Tamaño (MB)
Clientes	20.6	716
Contratos	40.6	560
Maestro Contratos	33.1	666
Curvas de carga	2,094.44	340,992

Una vez construido este primer dataset, se seleccionan los usuarios con: una potencia contratada igual o inferior a 10kW, una tarifa 2.0A o 20DHA, y que tengan con todas las lecturas de consumo del año 2016. Por último, se descartan las instancias con valores nulos. Este dataset está compuesto por 47,829,235 instancias correspondientes a las 365 curvas de carga de 2016 de 131,039 clientes. De cada consumidor, tenemos 24 lecturas de consumo horario para cada una de sus 365 instancias.

Para construir las series temporales de 2016 es necesario transformar este dataset de instancias diarias en uno de instancias anuales. De esta forma, el nuevo dataset constaría de 131,039 instancias, una por cliente, con: 8760 (365x24) lecturas horarias de 2016, la cups (Código Universal del Punto de Suministro), la tarifa y la potencia contratadas.

A continuación generamos un nuevo atributo con el que categorizamos a los consumidores en función a la potencia contratada. Por último, construimos un dataset alternativo con diferencias de consumo normalizadas: hallamos la diferencia entre cada par de valores de consumo consecutivo y la dividimos por la media de consumo de ese día. De esta forma tendremos un dataset con los consumos horarios de 2016 y otro con las diferencias normalizadas de consumo del mismo periodo. Estos datasets se utilizarán tanto de forma conjunta como individual en los siguientes apartados con el objetivo de encontrar patrones en los hábitos de consumo eléctrico de los clientes.

##### B. Determinación del número óptimo de clusters

Antes de aplicar algoritmos de clustering a nuestros datasets es necesario determinar cuál es el número óptimo de clusters ( $k$ ) a obtener. Para ello, aplicamos a cada uno de los datasets cuatro índices de validación de clustering para big data (BD-CVIs) [4]: BD-Silhouette [4], BD-Dunn [4], Davies-Bouldin [20] y Within Set Sum of Square Errors (WSSSE) [21].

En la Figura 1a se muestra la representación gráfica resultados índice BD-Silhouette. Para este índice los valores óptimos de  $k$  son sus máximos, 6 y 9. Estos valores coinciden con los máximos de la gráfica correspondiente al índice BD-Dunn (Figura 1b). En el caso del índice Davies-Bouldin los valores óptimos se encuentran en los mínimos,

que vuelven a coincidir en 6 y 9, tal y como se observa en la Figura 1c. Por último, los resultados del índice WSSSE representados en la Figura 1d no arrojan un valor claro. En este índice buscamos una estabilización de valores y, como podemos ver, no hay un valor concreto en lo que esto ocurra. Tras analizar estos resultados, hemos obtenido los valores 6 y 9 como óptimos para la realización del clustering.

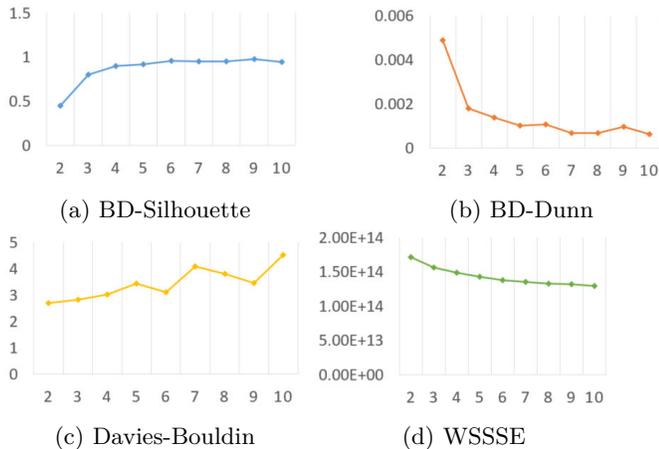


Fig. 1: Índices big data de validación de clustering

Al igual que para el dataset de consumos, hemos vuelto a aplicar estos índices al dataset de diferencias normalizadas comentado al final del apartado IV-A. En este caso, los resultados para el valor óptimo de  $k$  fueron 5 y 7.

### C. Clustering

Una vez calculado el número óptimo de clusters, aplicamos a cada dataset la versión implementada en Spark del algoritmo k-means. Esta implementación fue desarrollada para poder extraer patrones en sistemas paralelos y distribuidos. A la hora de ejecutar el algoritmo, le daremos como entrada el objeto RDD (Resilient Distributed Dataset) y el  $k$  obtenido anteriormente. Como resultado obtendremos una serie de clusters con elementos de cada uno de los datasets.

Para el dataset de consumos, dos de los clusters obtenidos con  $k=9$  tenían menos de 5 elementos, por lo que se decidió trabajar con el otro valor óptimo obtenido de  $k=6$ . En el caso del dataset de diferencias normalizadas, dos de los clusters para  $k=5$  contenían un único elemento. Por este motivo, se optó por tomar el valor  $k=7$ .

La distribución de los elementos en los 6 clusters del dataset de consumos se muestra en la Tabla IIIa. De la misma forma, en la Tabla IIIb podemos ver cómo se distribuyen los elementos correspondientes a los 7 clusters del dataset de diferencias normalizadas.

En la Figura 2 se representan las curvas de consumo horario formadas por los centroides de cada uno de los clusters durante una semana de enero de 2016. En ella destaca que la mayoría de los consumidores, agrupados

TABLE III: Clusters de los datasets para  $k$  óptimo

(a) Dataset de consumos para  $k=6$

Cluster	Elementos
0	12,029
1	50,643
2	1002
3	138
4	1116
5	43,789

(b) Dataset de diferencias normalizadas para  $k=7$

Cluster	Elementos
0	42,276
1	8241
2	2544
3	18,994
4	28,462
5	7191
6	1029

en los clusters 1 y 5, tienen consumos inferior a 1 kWh. También puede observarse como un grupo reducido de clientes, que conforma el cluster 3, tiene un consumo muy alto por la noche (de 19 a 8 horas) y prácticamente nulo durante el día.

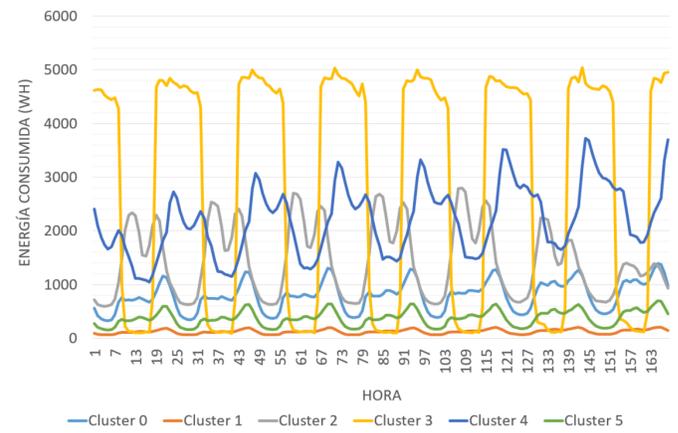


Fig. 2: Curvas de consumo horario de los centroides durante una semana de enero

En la Figura 3 se representan las las curvas de los mismos centroides durante una semana de julio. Se observa que los consumidores de los clusters 0, 1 y 5 mantienen un consumo prácticamente igual al de enero, aunque los picos máximo se acercan más a la media noche. Sin embargo, los del cluster descienden de forma radical hasta equipararse a los del 0. También destacan las curvas de consumo del cluster 3, donde las horas de alto consumo se reducen a 6 (00 a 6 horas).

Por su parte, la Figura 4 muestra las curvas de las diferencias horarias normalizadas en el mismo periodo de tiempo que la Figura 2. En ella podemos observar como los mayores picos de diferencias de consumo entre horas pertenecen a los elementos de los clusters 1,2,5 y 6. Estos clusters resultan ser los menos numerosos, representando un 17% del total de los consumidores. Lo que nos indica que el consumo de la mayoría de los usuarios a lo largo del día mantiene cierta uniformidad.

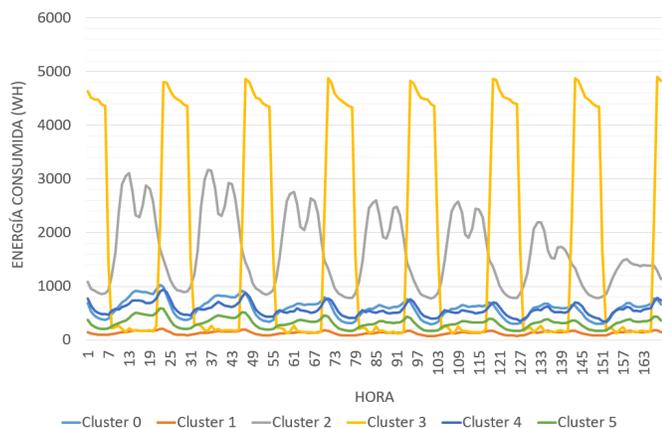


Fig. 3: Curvas de consumo horario de los centroides durante una semana de julio



Fig. 4: Curvas de diferencias horarias normalizadas de los centroides

#### D. Evaluación de resultados

1) *Evaluación no supervisada*: En esta última fase evaluaremos los resultados obtenidos tras aplicar el algoritmo k-means a los datasets. Para ello, se generan las tablas de contingencia entre los clusters obtenidos para los distintos datasets, cruzando los resultados entre los mismos. Esto nos permite encontrar patrones que definan a los consumidores en relación a las características de los diferentes conjuntos de datos.

La tabla de la Figura 5 muestra por filas los 6 clusters del dataset de consumos (C0 a C5), y por columnas los 7 obtenidos del dataset de diferencias normalizadas (D0 a D6). Estos valores representan los porcentajes relativos al total de cada fila. Es decir, el porcentaje de consumidores de cada cluster de consumos presente en cada uno de los clusters de diferencias normalizadas.

En la Figura 5 destaca que casi la totalidad del cluster C3 está formado por consumidores del cluster D6. Si atendemos a la Figura 2 esto caracterizaría a un grupo de clientes con un consumo nocturno muy alto. Si además

		CLUSTER DIFERENCIAS NORMALIZADAS							
		D0	D1	D2	D3	D4	D5	D6	
CLUSTER CONSUMOS	C0	29.11%	10.20%	3.85%	19.03%	27.53%	9.85%	0.43%	100.00%
	C1	53.06%	5.25%	1.87%	13.03%	20.61%	4.74%	1.44%	100.00%
	C2	52.20%	1.60%	27.64%	7.98%	7.29%	3.19%	0.10%	100.00%
	C3	5.07%	0.00%	0.00%	0.00%	0.00%	0.72%	94.20%	100.00%
	C4	56.16%	7.83%	0.09%	7.13%	16.99%	8.36%	3.43%	100.00%
	C5	24.51%	9.70%	1.96%	22.71%	32.99%	7.94%	0.18%	100.00%

Fig. 5: Tabla de contingencia de valores relativos al total de cada fila

nos fijamos en la Figura 4, observamos que tienen un mínimo y un máximo en las diferencias horarias que se mantiene constante los 7 días de la semana. Esto podría indicar un perfil de consumidor muy concreto, con un consumo energético nocturno alto y uniforme. Por otro lado, podemos observar que la mitad cluster C1, el más numeroso, está formado por consumidores del cluster D0, también el más numeroso. Aquí se identifica un amplio grupo de usuarios de consumo bajo y con pocos cambios, cuyas mayores variaciones en el consumo se producen a las 8h.y 18h.

A continuación vamos a analizar el cluster C5, de un tamaño similar al C1 y con un consumo un poco más alto. En este caso, sólo se compone en un 24.51% de consumidores del cluster D0. Sin embargo, aumenta considerablemente el número de elementos pertenecientes a los clusters D3 y D4. En ellos, las diferencias de consumo horario (algo más altas que en el anterior) se concentran en las 19h. en los consumidores del cluster D3 y las 21 h. en los de D4. Por lo que podemos interpretar que los clientes con un consumo algo mayor que los del cluster C1 son más heterogéneos en cuanto a su comportamiento.

Ahora analizaremos los resultados desde la otra perspectiva. En la Figura 6 se representan los porcentajes relativos al total de cada columna. Es este caso, el porcentaje de consumidores de cada cluster de diferencias normalizadas presente en cada uno de los clusters de consumos.

		CLUSTER DIFERENCIAS NORMALIZADAS						
		D0	D1	D2	D3	D4	D5	D6
CLUSTER CONSUMOS	C0	8.28%	14.89%	18.20%	12.05%	11.63%	16.48%	5.05%
	C1	63.56%	32.29%	37.15%	34.74%	36.68%	33.39%	70.65%
	C2	1.24%	0.19%	10.89%	0.42%	0.26%	0.45%	0.10%
	C3	0.02%	0.00%	0.00%	0.00%	0.00%	0.01%	12.63%
	C4	1.51%	1.08%	0.04%	0.43%	0.68%	1.32%	3.79%
	C5	25.39%	51.55%	33.73%	52.36%	50.76%	48.35%	7.77%
		100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%

Fig. 6: Tabla de contingencia de valores relativos al total de cada columna

Si nos fijamos en la Figura 6, lo primero que podemos destacar es que todos los clusters de diferencias normalizadas están compuestos mayoritariamente por los clusters C1 y C5. Algo normal debido entre los dos aglutinan el 86% del total de consumidores. Los clusters D0 y D1 tienen una mayoría de elementos de C1, mientras que los clusters D1, D3, D4 y D5 tienen una mayor presencia de elementos del C5. Por otro lado, en el D2 los clusters C1

y C5 no tienen una representación tan alta debido al 10% de elementos del cluster C2.

Centrándonos en el cluster D6, vemos que el 70.65% de sus clientes pertenecen al cluster C1. Mientras que observando la Figura 5 se denota que sólo el 1.44% de los del cluster C1 de consumos pertenecen al cluster D6.

2) *Evaluación semi-supervisada:* En este apartado tomaremos como referencia el rango de potencia contratada al que pertenece cada consumidor. Por lo que cruzamos elementos de los clusters del dataset de consumo (Ver Tabla IIIa) con los de cada rango de potencia (ver Tabla Ib). El objetivo es encontrar relaciones entre los distintos tipos de consumidores y sus potencias contratadas. En la tabla de contingencia de la Figura 7 se representan los clusters del dataset de consumos por filas (C0 a C5) y los rangos de potencia por columnas (P1 a P8). Estos valores representan los porcentajes relativos al total de cada fila. Es decir, el porcentaje de consumidores de cada cluster de consumos presente en cada uno de los rangos de potencia.

CLUSTER CONSUMOS	RANGO DE POTENCIA								
	P1	P2	P3	P4	P5	P6	P7	P8	
C0	2.65%	9.51%	27.46%	23.09%	17.67%	6.66%	12.80%	0.17%	100.00%
C1	13.76%	26.37%	34.08%	17.74%	4.43%	1.50%	2.08%	0.03%	100.00%
C2	2.69%	5.29%	12.28%	16.87%	14.87%	19.56%	26.85%	1.60%	100.00%
C3	3.62%	0.72%	10.87%	21.74%	10.14%	47.10%	4.35%	1.45%	100.00%
C4	4.15%	9.01%	12.54%	15.19%	26.50%	19.08%	12.90%	0.62%	100.00%
C5	3.67%	16.70%	40.50%	23.28%	8.89%	2.50%	4.41%	0.05%	100.00%

Fig. 7: Tabla de contingencia de valores relativos al total de cada fila

Si observamos los clusters C1 y C5, los de menor consumo (ver Figura 2), comprobamos que la mayoría de sus elementos pertenece a los rangos P1 a P4, las potencias bajas. Mientras, en los clusters C2 y C4 aumentan de forma considerable los consumidores con potencias más altas (P5, P6 y P7). Como es lógico, la mayoría de los clientes con consumo bajo tienen contratadas potencias medias y bajas. Además, más de la mitad de los clientes con un consumo alto contrató una potencia alta. Un caso particular es el C3, donde casi la mitad de sus elementos pertenecen a P6. Esto indica que cerca del 50% de los clientes con alto consumo nocturno tienen contratados entre 6.90 y 8.05kW.

Ahora vamos a analizarlo desde el punto de vista de la potencia contratada. Si observamos la Figura 8, se representan los porcentajes relativos al total de cada columna. Es decir, el porcentaje de consumidores de cada rango de potencia presente en cada uno de los clusters de consumos.

Podemos ver como más del 85% de los consumidores de los rangos P1 a P4 pertenecen a los clusters C1 y C5. Por lo que la relación entre estos grupos de clusters y rangos de potencia existe en ambos sentidos: Clientes con bajo consumo contrató un nivel potencia baja o media y viceversa. En el análisis de la Figura 7 vimos como los clientes con alto consumo tenían potencias altas contratadas. Pero, si nos fijamos en los rangos P5 a P8,

CLUSTER CONSUMOS	RANGO DE POTENCIA							
	P1	P2	P3	P4	P5	P6	P7	P8
C0	3.54%	5.20%	8.55%	12.42%	24.34%	25.53%	31.10%	24.39%
C1	77.66%	60.80%	44.75%	40.25%	25.72%	24.31%	21.33%	15.85%
C2	0.30%	0.24%	0.32%	0.76%	1.71%	6.25%	5.44%	19.51%
C3	0.06%	0.00%	0.04%	0.13%	0.16%	2.07%	0.12%	2.44%
C4	0.52%	0.46%	0.37%	0.77%	3.44%	6.89%	2.95%	8.54%
C5	17.92%	33.28%	45.98%	45.66%	44.63%	34.94%	39.06%	29.27%
	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%

Fig. 8: Tabla de contingencia de valores relativos al total de cada columna

observamos que éstos también están compuestos entre un 45% y un 70% por clientes con bajo consumo. Por lo que, aunque los clientes con alto consumo tienen potencias altas contratadas, la mayoría de consumidores con estas potencias tienen un bajo consumo. Al igual que antes, nos vamos a centrar el caso de P6 y C3. Mientras que el 47.1% de los consumidores de C3 pertenecían a P6, sólo el 2.07% de los de P6 se encuentran en C3. Esto refuerza la conclusión anterior, ya que más del 85% de los consumidores con potencia entre 6.9 y 8.05kW tienen consumos que rondan entre los 0.5 y 1.5kWh.

## V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se ha presentado la aplicación de técnicas big data para el análisis de datos de consumidores eléctricos. La caracterización de estos clientes obtenida como resultado da lugar a las siguientes conclusiones:

- Más del 85% de los clientes presentan curvas de carga de consumo donde los valores máximos no superan el kWh.
- Existe grupo de 138 clientes con un consumo nocturno muy alto. Y, aunque la cantidad de horas de consumo durante el verano es muy inferior al invierno, siempre se producen en periodos valle. El 97.8% de estos usuarios tienen contratada una tarifa adaptada a sus consumos, con discriminación horaria.
- En su inmensa mayoría, los clientes con un bajo consumo tenían contratada una baja potencia y viceversa.
- Los usuarios con un consumo medio-alto contrataron una potencia media-alta. Sin embargo, el 77.32% de los clientes que contrataron estos niveles de potencia, consumió valores de energía que no llegaron a 1kWh. Por lo que más de 3/4 partes de estos clientes tienen potencias contratadas muy por encima de lo que necesitan.
- Durante todo el año, los picos de consumo que se alcanzan por las mañanas y al mediodía se producen en horarios valle. Lo mismo ocurre con los picos nocturnos en verano, ya que estos aparecen entre las 23 y la 1. Esto indica que las tarifas de discriminación horaria podrían ser beneficiosas para los clientes con estos hábitos de consumo. Sin embargo, sólo el 5% (4,784 de 95,569 clientes) tienen contratada este tipo de tarifa.



- En trabajos futuros se caracterizará a los consumidores en función de sus consumos y tarifas. Además, se analizarán y recomendarán las tarifas y potencias óptimas a contratar de forma personalizada para cada tipo de cliente.

## REFERENCES

- [1] K. Shvachko, H. Kuang, S. Radia, and R. Chansler, "The hadoop distributed file system," in *2010 IEEE 26th Symposium on Mass Storage Systems and Technologies (MSST)*, May 2010, pp. 1–10.
- [2] M. Zaharia, M. Chowdhury, M. J. Franklin, S. Shenker, and I. Stoica, "Spark: Cluster computing with working sets," vol. 10, pp. 10–10, 07 2010.
- [3] X. Meng, J. Bradley, B. Yavuz, E. Sparks, S. Venkataraman, D. Liu, J. Freeman, D. Tsai, M. Amde, S. Owen, D. Xin, R. Xin, M. J. Franklin, R. Zadeh, M. Zaharia, and A. Talwalkar, "Mllib: Machine learning in apache spark," *Journal of Machine Learning Research*, vol. 17, no. 34, pp. 1–7, 2016.
- [4] J. M. Luna-Romera, J. García-Gutiérrez, M. Martínez-Ballesteros, and J. C. Riquelme Santos, "An approach to validity indices for clustering techniques in big data," *Progress in Artificial Intelligence*, vol. 7, no. 2, pp. 81–94, Jun 2018.
- [5] H. T. Haider, O. H. See, and W. Elmenreich, "A review of residential demand response of smart grid," *Renewable and Sustainable Energy Reviews*, vol. 59, pp. 166 – 178, 2016.
- [6] I. Hussain, S. Mohsin, A. Basit, Z. A. Khan, U. Qasim, and N. Javaid, "A review on demand response: Pricing, optimization, and appliance scheduling," *Procedia Computer Science*, vol. 52, pp. 843 – 850, 2015.
- [7] H. T. Haider, O. H. See, and W. Elmenreich, "Residential demand response scheme based on adaptive consumption level pricing," *Energy*, vol. 113, pp. 301 – 308, 2016.
- [8] F. Martínez-Álvarez, A. Troncoso, G. Asencio-Cortés, and J. C. Riquelme, "A survey on data mining techniques applied to electricity-related time series forecasting," *Energies*, vol. 8, no. 11, pp. 13 162–13 193, 2015.
- [9] T. chung Fu, "A review on time series data mining," *Engineering Applications of Artificial Intelligence*, vol. 24, no. 1, pp. 164 – 181, 2011.
- [10] S. Aghabozorgi, A. S. Shirkhorshidi, and T. Y. Wah, "Time-series clustering – a decade review," *Information Systems*, vol. 53, pp. 16 – 38, 2015.
- [11] H. Wang, W. Wang, J. Yang, and P. Yu, "Clustering by pattern similarity in large data sets," vol. 3, 10 2002.
- [12] F. Iglesias and W. Kastner, "Analysis of similarity measures in times series clustering for the discovery of building energy patterns," *Energies*, vol. 6, no. 2, pp. 579–597, 2013.
- [13] T. Zhang, G. Zhang, J. Lu, X. Feng, and W. Yang, "A new index and classification approach for load pattern analysis of large electricity customers," *IEEE Transactions on Power Systems*, vol. 27, no. 1, pp. 153–160, Feb 2012.
- [14] F. Martínez-Álvarez, A. Troncoso, J. C. Riquelme, and J. M. Riquelme, "Partitioning-clustering techniques applied to the electricity price time series," in *Proceedings of the 8th International Conference on Intelligent Data Engineering and Automated Learning*, ser. IDEAL'07. Berlin, Heidelberg: Springer-Verlag, 2007, pp. 990–999.
- [15] F. M. Alvarez, A. Troncoso, J. C. Riquelme, and J. S. A. Ruiz, "Energy time series forecasting based on pattern sequence similarity," *IEEE Transactions on Knowledge and Data Engineering*, vol. 23, no. 8, pp. 1230–1243, Aug 2011.
- [16] P. Faria, Z. Vale, and J. Baptista, "Demand response programs design and use considering intensive penetration of distributed generation," *Energies*, vol. 8, no. 6, pp. 6230–6246, 2015.
- [17] S. Haben, C. Singleton, and P. Grindrod, "Analysis and clustering of residential customers energy behavioral demand using smart meter data," *IEEE Transactions on Smart Grid*, vol. 7, no. 1, pp. 136–144, Jan 2016.
- [18] J.-S. Chou and N.-T. Ngo, "Smart grid data analytics framework for increasing energy savings in residential buildings," *Automation in Construction*, vol. 72, pp. 247 – 257, 2016.
- [19] R. Perez-Chacon, R. L. Talavera-Llames, F. Martinez-Alvarez, and A. Troncoso, "Finding electric energy consumption patterns in big time series data," in *Distributed Computing and Artificial Intelligence, 13th International Conference*, S. Omatu, A. Semalat, G. Bocewicz, P. Sitek, I. E. Nielsen, J. A. García García, and J. Bajo, Eds. Cham: Springer International Publishing, 2016, pp. 231–238.
- [20] D. L. Davies and D. Bouldin, "A cluster separation measure," vol. PAMI-1, pp. 224 – 227, 05 1979.
- [21] "Spark clustering rdd based api documentation for spark 2.3.0. 2017." <https://spark.apache.org/docs/2.3.0/mllib-clustering.html>, accessed: 2018-06-11.

# Un procedimiento efectivo para descomponer y modelar series temporales en agricultura

Francisco Aragón, Francisco Javier Baldán, Manuel Parra, José M. Benítez

*Depto. Ciencias de la Computación e Inteligencia Artificial, DICITS, DaSCI*

*Universidad de Granada*

*Granada, España*

{far, fjbaldan, manuelparra, J.M.Benitez}@decsai.ugr.es

**Resumen**—En este trabajo proponemos una forma innovadora de abordar casos reales de predicción de la producción de cultivos en una cooperativa. Nuestro enfoque consiste en la descomposición de la serie temporal original de los cultivos en sub-series temporales según una serie de factores, con el objetivo de generar un modelo predictivo del cultivo a partir de los modelos predictivos parciales de las sub-series. El ajuste de los modelos se realiza mediante un conjunto de técnicas estadísticas y de Aprendizaje Automático. Esta metodología se ha comparado con una metodología intuitiva que consiste en una predicción directa de las series temporales. Los resultados muestran que nuestro enfoque logra un mejor rendimiento de predicción que la manera directa, por lo que aplicar una metodología de descomposición es más adecuada para este problema que la no descomposición.

**Palabras Clave**—agricultura, predicción, modelos predictivos, series temporales, descomposición

## I. INTRODUCCIÓN

La agricultura es una actividad económica que resulta de vital importancia en prácticamente todos los países del mundo. En los últimos años la mejora del rendimiento agrícola (cantidad de producción obtenida por área cultivada) había sido propiciada por avances en la maquinaria empleada, nuevas técnicas de siembra, así como mediante la mejora de semillas y agroquímicos o un mejor control de plagas y enfermedades. Pero ahora, la agricultura comercial se ha vuelto una actividad de alta tecnología, en la que los avances tecnológicos informáticos también tienen su aplicación ya que permiten generar información de alta calidad sobre los procesos productivos.

Por lo tanto, la agricultura puede beneficiarse del auge de las técnicas englobadas dentro del ámbito de la Inteligencia Artificial y del Análisis de Datos, para crear modelos predictivos que predigan situaciones futuras que sean de ayuda para mejorar tanto la productividad de las cosechas como la toma de decisiones en todo lo relativo a ellas. Dentro del ámbito de la agricultura una gran cantidad de procesos tales como la producción o la aparición de plagas entre otras, pueden modelarse como una colección de observaciones habitualmente ordenadas a lo largo de un periodo de tiempo, es decir, mediante una serie temporal. Por medio de la aplicación sobre las series temporales de un conjunto de técnicas estadísticas y de Aprendizaje Automático se pueden generar modelos

predictivos que sean capaces de extraer sus regularidades y de realizar predicciones.

Estos modelos predictivos resultantes de los análisis de los datos, pueden ser de gran importancia en las cooperativas y asociaciones de las que dependen los pequeños agricultores a la hora de la toma de decisiones en una gran cantidad de situaciones cotidianas relacionadas por ejemplo con la gestión de plagas, de los cultivos en el campo, o la gestión de la producción esperada ya sea para ofertarla en el mercado, para contratar el personal necesario para tratarla o para obtener el material necesario para su preparación y embalaje. La eficiencia en todas estas situaciones va a depender de la capacidad de transformar los datos brutos en información precisa que permita tomar la decisión acertada en cada una de ellas, siendo la gestión de la producción una de las actividades de mayor importancia. Por ello, disponer de información fiable sobre las expectativas de producción es crítico en el sector agrícola.

En este artículo se propone descomponer las series temporales del rendimiento de un cultivo en un conjunto de sub-series temporales en función de una serie de factores, siendo clave la semana de plantación, con la intención de que con la descomposición se obtengan sub-series con patrones más establecidos que la serie original general. El análisis y ajuste de los modelos predictivos de las sub-series temporales se realiza mediante una batería de métodos estadísticos como son los métodos ARIMA [3] y de Aprendizaje Automático como son las redes neuronales entre otras, para a partir de ellos, realizar una predicción general de los kilogramos del cultivo. La metodología propuesta se ha evaluado en varios casos de estudio reales, y se ha comparado con una metodología directa que consiste en una predicción de las series temporales sin descomponer. Los resultados muestran como se obtiene una mejora de la predicción al aplicar la metodología planteada con respecto a la serie sin descomponer.

El resto del artículo está organizado de la siguiente manera: la sección 2 describe el estado actual en que se encuentra la aplicación de modelos predictivos sobre problemas de predicción de cosechas modelados como series temporales. La sección 3 describe el problema, la forma en que ha llevado a cabo la descomposición, y la metodología empleada para resolverlo. En la sección 4 se detalla la experimentación realizada, se muestra el conjunto de datos y los resultados



obtenidos. En la sección 5 se discuten los resultados obtenidos. Por último, la sección 6 presenta las conclusiones obtenidas tras la realización del trabajo.

## II. ESTADO DEL ARTE

En el ámbito de la agricultura, los investigadores han propuesto numerosos modelos y procedimientos para mejorar la predicción de cosechas. La mayoría de ellos han tenido un enfoque multivariante, en los que se trata de incorporar a la predicción el impacto que numerosas variables relativas a cultivos tales como la lluvia, la temperatura, los fertilizantes o la calidad del suelo tienen en la cosecha. Los métodos más ampliamente empleados para realizar este tipo de modelos multivariantes son las redes neuronales, más en concreto en su variante *feed-forward*. En [10] y [12] se desarrollan estudios sobre si redes neuronales con variables relacionadas al cultivo son adecuadas para realizar la predicciones futuras, realizan una evaluación de la capacidad predictiva de diferentes parametrizaciones de la red, y comparan los resultados con otros modelos de regresión. En otros trabajos como en [14] se ha realizado un estudio concreto de las variables óptimas para la predicción de cosecha de maíz. Existe un déficit de trabajos en cuanto a la predicción de cosechas que tengan un enfoque multivariante y que además empleen métodos distintos a redes neuronales. Algunos de esos trabajos son [6] y [9], que demuestran la capacidad de métodos de *Random Forests (RF)* para la estimación de cultivos, y en [4] para máquinas de soporte vectorial. En [16] se realiza una comparación entre diferentes metodos regresivos como redes neuronales, funciones de base radial o árboles de regresión.

En cuanto a un enfoque univariante, los métodos ARIMA son los más ampliamente usados en la predicción de cosechas. En [15] se emplean los métodos ARIMA para predecir el área y la producción de trigo en los próximos años. También los alisados exponenciales los acompañan en algunos trabajos como en [1]. En [5] se realiza una comparación sobre la capacidad predictiva entre los métodos ARIMA y los alisados exponenciales.

La mayoría de los trabajos que se han realizado en este ámbito se han realizado desde un punto de vista multivariante, centrando el estudio en la importancia del impacto de los factores endógenos sobre la variable a predecir. Las redes neuronales y los métodos ARIMA son los más empleados, siendo también aplicados aunque en menor medida las máquinas de soporte vectorial o los métodos *Random Forest*. Son menos los trabajos en los que se ha empleado un enfoque univariante que trabaje directamente sobre la serie temporal. Aún así, los trabajos tratan de una manera muy superficial a la serie temporal ya que no tratan de adaptarla o modificarla para obtener una serie más fácil de predecir, sino que se centran directamente en aplicar un método concreto, con diferentes entradas o diferentes parametrizaciones para obtener una mejor predicción. Además, los trabajos solo emplean un método para el análisis de la serie, obviando la posibilidad de combinar varios métodos sobre la misma serie mediante una subdivisión de la misma.

## III. PROPUESTA

Para hacer una declaración más precisa se formaliza el problema de predicción abordado, por lo que a continuación se detalla nuestra propuesta.

### III-A. Descripción del problema y formulación

El problema se ubica en el ámbito de una cooperativa de frutas y hortalizas. La cooperativa está compuesta de un conjunto de parcelas, pertenecientes a los agricultores asociados, y la producción se divide en campañas, que representan los años agrícolas, de septiembre a julio. Cada parcela planta un producto específico durante una campaña. La superficie de cultivo de las parcelas se mide en metros cuadrados y cada parcela tiene su propia superficie. Los productos que se plantan en la cooperativa son diferentes variedades de frutas y verduras y su producción se mide en kilogramos. La producción total de un producto está formada por la suma de la producción de cada parcela que planta el producto. Algunos de los productos se plantan durante un cierto periodo de tiempo, siguiendo un patrón de siembra similar en cada campaña, mientras que otros se plantan de forma irregular a lo largo de la campaña. La producción durante el ciclo de vida de un cultivo suele ser similar para el mismo producto, por lo que para los productos plantados en periodos cercanos la producción sigue un patrón similar.

El principal interés de la cooperativa reside en conocer la producción en unidades de peso (p.e. kilogramos) que producirá cada producto para la próxima semana, de manera que la cooperativa pueda manejar adecuadamente el volumen de producción que se tendrá. Por lo tanto, la mejor manera de medir la producción es de forma semanal, y el problema a tratar consiste en la predicción de la producción en kilogramos de producto para la próxima semana. Este problema se abordará descomponiendo las series temporales de producción en sub-series temporales de semanas de siembra significativas, y empleando sobre ellas técnicas de Inteligencia Artificial y métodos estadísticos para generar modelos predictivos cuyas predicciones se irán agregando para obtener finalmente la producción global.

### III-B. Descomposición de las series temporales

La idea principal del enfoque de descomposición en sub-series temporales es capturar el comportamiento similar que debe tener la producción de un producto que ha sido plantado en el mismo corto periodo de tiempo, ya que su ciclo de vida será muy parecido. Por lo tanto, el principal criterio de descomposición está tomado de uno de los factores más influyentes en la producción: la fecha de siembra. Las fechas de plantación se agrupan por semanas. La descomposición se realiza en semanas de siembra significativas y habrá tantas sub-series temporales como semanas de plantación significativas se establezcan. Las semanas significativas son aquellas que presentan un gran número de parcelas en plantación y por tanto la mayor parte de la producción del producto. Para determinar el conjunto de semanas significativas, se computan

las frecuencias de las semanas de siembra durante las campañas anteriores para analizar el número de parcelas que han plantado el producto en cada semana, y por lo tanto elegir las semanas con una mayor frecuencia de parcelas en plantación. Las semanas cuyas frecuencias de siembra son pequeñas se agrupan en una o dos series temporales adicionales.

Para los casos particulares bajo estudio, la descomposición se hizo como se expresa en la Tabla I. La Tabla I revela la elección de semanas significativas para los productos, y por lo tanto el número de sub-series temporales. El producto 1 tiene tres importantes semanas consecutivas de plantación; 37, 38 y 39 que cubren el 70% de las parcelas. Para el producto 2 las semanas elegidas presentan cierta dispersión ya que tiene sus semanas significativas entre la 8 y la 11 y entre la 31 y la 38, representando el 67% del total de parcelas. En general, para ambos productos predomina la plantación en las semanas correspondientes a los meses de agosto y septiembre.

Tabla I  
SEMANAS DE PLANTACIÓN SELECCIONADAS PARA CADA SUB-SERIE

Nº de la subserie	Semanas de plantación de la subserie	
	Producto 1	Producto 2
Sub1	37	8-9
Sub2	38	10-11
Sub3	39	31-32
Sub4	-	33-34
Sub5	-	35-36
Sub6	-	37-38
Sub7	-	Entre la 12 y la 30
Sub8	-	No entre la 12 y la 30

### III-C. Metodología

Para resolver el problema, proponemos desarrollar modelos que predigan la producción de un producto para la semana siguiente. Esta producción se modela como una serie temporal del rendimiento histórico semanal del producto. El rendimiento del cultivo se utiliza como valor de la serie temporal en lugar de los kilogramos, ya que elimina el efecto de la influencia que tiene la superficie sobre el número total de kilogramos producidos por una parcela en un periodo. El rendimiento global de cada producto se obtiene dividiendo la suma total de los kilogramos producidos por las parcelas en producción en cada periodo de tiempo por la suma de las superficies de las parcelas que contribuyen en ese periodo de tiempo.

$$\text{Rendimiento de cultivo} = \frac{\sum kg}{\sum \text{superficie}} \quad (1)$$

La metodología propuesta para desarrollar los modelos predictivos se basa en la descomposición de las series temporales del rendimiento de los cultivos de un producto en sub-series temporales. En cada sub-serie temporal solo se tratan los cultivos que han sido plantados en un periodo de tiempo muy corto, por lo que como paso esencial para nuestra metodología se deben analizar y agrupar las semanas de plantación para aprovechar la homogeneidad en la duración y producción del cultivo y además cubrir el mayor número de parcelas posible.

Como resultado de esto, las sub-series temporales que se obtengan presentarán comportamientos más predecibles.

Una vez que se tienen las sub-series parciales de un producto, se ajusta un modelo predictivo para cada una de ellas. El proceso de construcción del modelo predictivo sigue los siguientes pasos:

1. Preprocesamiento: Se realiza una imputación de valores faltantes en las sub-series temporales en caso de que existan, para que todas las sub-series temporales tengan la misma longitud. Además, se realiza una normalización min-max entre el rango [0,1]:

$$\text{normalización } TS = \frac{TS - \min_{TS}}{\max_{TS} - \min_{TS}} \quad (2)$$

donde  $TS$  denota la sub-serie temporal original, y  $\min_{TS}$  y  $\max_{TS}$  los valores mínimo y máximo de la sub-serie temporal. Por último, las series parciales se dividen en datos de entrenamiento y datos de prueba.

2. Modelado: Se ajustan modelos predictivos de las sub-series temporales de entrenamiento utilizando un conjunto de técnicas estadísticas y de *machine learning* (ARIMA, alisados exponenciales, máquinas de soporte vectorial, *random forest*, redes neuronales, redes neuronales parcialmente recurrentes y modelos aditivos). Para cada una de las técnicas anteriores se generan un conjunto de modelos en función de las diferentes parametrizaciones empleadas.
3. Validación: El paso de validación determina en primer lugar cuál es el modelo más adecuado para cada técnica y, a partir de él, cuál es el mejor modelo global. El mejor modelo será aquel que obtenga una menor medida de error y por tanto una mayor capacidad predictiva. Para evaluar el error y la capacidad predictiva de cada uno de los modelos generados se aplica una validación cruzada *leave-one-out* [7] sobre las sub-series temporales de prueba. Para esta variante de la validación cruzada, existe un único valor de prueba para cada iteración, con la particularidad de que el conjunto de entrenamiento está formado por los valores que se producen temporalmente antes del valor de prueba. Así pues, no se usan valores futuros al valor de prueba en el entrenamiento del modelo. En cada iteración, el valor de prueba de la iteración anterior se incorpora al conjunto de entrenamiento, y el siguiente valor temporal que antes no ha sido usado se incorpora como valor de prueba.
4. Predicción: Después de completar los pasos anteriores, se tiene el modelo predictivo más adecuado para cada sub-serie temporal. A partir de estos modelos se genera una predicción para la semana siguiente del rendimiento de cultivo en cada sub-serie temporal. La predicción en kilogramos se obtiene multiplicando el rendimiento previsto obtenido de la cosecha y la superficie estimada de cultivo de las parcelas:

$$kg = \text{rendimiento} * \text{superficie} \quad (3)$$



El área de cultivo se estima a partir de las parcelas que han plantado en la presente campaña. Para ello se añade la superficie de todas las parcelas plantadas, menos la superficie de aquellas parcelas que han plantado y que no han podido producir al llevar plantadas menos días del tiempo que el producto necesita para empezar a producir, y aquellas parcelas que ya han terminado de producir.

5. Agregación: Para obtener la predicción global de kilogramos, se suman los valores pronosticados de kilogramos de cada sub-serie temporal.

$$KG = \sum_{i=1}^n kg_i \quad (4)$$

Dónde  $i = \{1, 2, \dots, n\}$  es el número de sub-series temporales.

#### IV. ESTUDIO EMPÍRICO

En esta sección, se describe el estudio empírico que hemos diseñado para evaluar la validez y el desempeño de nuestra propuesta de predicción para el problema abordado. La metodología se ha aplicado a casos reales. Se detallan los conjuntos de datos, las medidas de rendimiento y los enfoques competitivos. Después, se presentan los resultados empíricos obtenidos tras la realización de los experimentos.

##### IV-A. Procedimiento

Para comprobar la validez, el enfoque propuesto en este trabajo se ha comparado con un enfoque de predicción directo del problema. Esta estrategia directa consiste en aplicar algunos métodos de predicción a la serie temporal completa sin ningún tipo de descomposición. Las diferentes técnicas de predicción empleadas son ampliamente utilizadas en el estado del arte actual. En particular, los modelos considerados son: ARIMA, redes neuronales, máquinas de soporte vectorial, alisados exponenciales, redes neuronales parcialmente recurrentes, *Random Forest* y el modelo aditivo *Facebook Prophet* [17]. Argumentamos que este enfoque directo obtiene una menor capacidad predictiva, y por lo tanto, un enfoque más efectivo es considerar la descomposición basada en la semana de siembra.

##### IV-B. Configuración

Las series temporales de los productos y las sub-series temporales son univariantes. El periodo de las series temporales y las sub-series temporales se ha establecido en 52. Cada observación de la serie temporal y las sub-series temporales representa un valor semanal. Los valores de las series temporales se dividen en conjunto de entrenamiento y conjunto de pruebas. El porcentaje de valores en entrenamiento para todas las series temporales es el primer 65% de los valores totales, dejando el 35% restante como conjunto de pruebas. La longitud de la serie temporal del producto 1 es de 248, 161 valores para entrenamiento y 87 para la prueba. Para el segundo producto la longitud es de 222, 144 valores para el entrenamiento y 78 para la prueba. Se ha utilizado el error

cuadrático medio (RMSE) y el error absoluto medio (MAE) como medida del rendimiento:

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (o_t - \bar{p}e_t)^2} \quad (5)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |o_t - \bar{p}e_t| \quad (6)$$

donde  $o_t$  denota el valor de rendimiento original de la sub-serie temporal,  $pe_t$  el valor de rendimiento predicho y  $T$  el número de valores de prueba. Por otro lado, todo el procesamiento se ha implementado en el lenguaje de programación R, utilizando gran cantidad de los paquetes disponibles en el repositorio CRAN [2], [8], [11], [13], [17].

##### IV-C. Conjunto de datos

Los datos de producción se han recogido de una cooperativa situada en el sur de España. Para este trabajo se han seleccionado dos cultivos:

- Producto 1. Vegetal de temporada. La producción de rendimiento para este producto está disponible desde septiembre de 2013 hasta abril de 2018, cubriendo las campañas 2013, 2014, 2015, 2016 y 2017. La plantación principal tiene lugar en el mes de septiembre, pero también se realizan pequeñas plantaciones en los meses de agosto y febrero.
- Producto 2. Fruta de temporada. La producción de rendimiento para este producto está disponible desde enero de 2014 hasta abril de 2018, cubriendo la mitad de la campaña de 2013 y las campañas completas de 2014, 2015 y 2016 y gran parte de la de 2017. La plantación principal ocurre en los meses de agosto-septiembre y en los meses de febrero-marzo.

##### IV-D. Resultados

La Tabla II muestra el RMSE en prueba obtenido con nuestra metodología propuesta y con el enfoque directo. La Tabla III muestra el MAE. En las filas de la primera columna de ambas tablas se muestra la metodología empleada, ya sea la metodología propuesta en este trabajo o la metodología directa. La segunda columna especifica el método de modelado empleado por la metodología, en el caso de la metodología propuesta se han empleado una combinación de todos los métodos para ajustar la serie, pero en el caso de la metodología directa se ha empleado solo un método en cada caso. La columna 3 se subdivide en dos columnas siendo cada una referente al error cometido en cada producto. Todos los valores RMSE y MAE están normalizados en el rango [0-1].

#### V. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

Los resultados de la Tabla II y Tabla III muestran como nuestro enfoque logra una mejor capacidad predictiva que el enfoque directo para cada uno de los casos reales al obtener un error menor tanto en RMSE como en MAE.

Tabla II  
RMSE NORMALIZADO OBTENIDO POR NUESTRA PROPUESTA Y DE MANERA DIRECTA SOBRE EL SUBCONJUNTO DE PRUEBA

Metodología	Modelo usado	Error cometido (RMSE)	
		Producto 1	Producto 2
Propuesta	Todos	<b>0.0371</b>	<b>0.0368</b>
Directa	ARIMA	0.0536	0.0458
Directa	Red Neuronal	0.0502	0.0446
Directa	SVM	0.0643	0.0685
Directa	Alisado Exponencial	0.0565	0.0475
Directa	Red Neuronal Parcialmente Recurrente	0.0457	0.0445
Directa	Random Forest	0.0658	0.0487
Directa	Modelo Aditivo	0.0600	0.0579

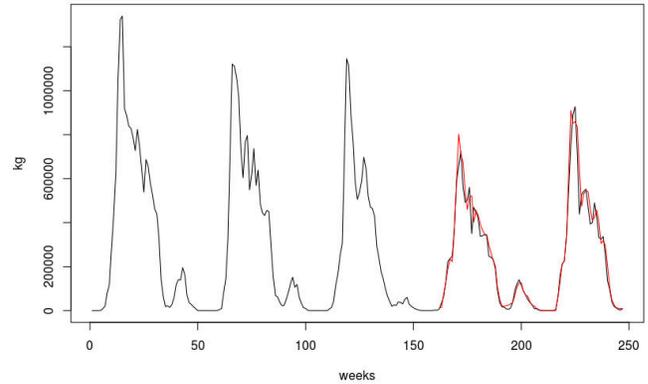
Tabla III  
MAE NORMALIZADO OBTENIDO POR NUESTRA PROPUESTA Y DE MANERA DIRECTA SOBRE EL SUBCONJUNTO DE PRUEBA

Metodología	Modelo usado	Error cometido (MAE)	
		Producto 1	Producto 2
Propuesta	Todos	<b>0.0214</b>	<b>0.0247</b>
Directa	ARIMA	0.0346	0.0400
Directa	Red Neuronal	0.0331	0.0292
Directa	SVM	0.0485	0.0403
Directa	Alisado Exponencial	0.0384	0.0350
Directa	Red Neuronal Parcialmente Recurrente	0.0346	0.0302
Directa	Random Forest	0.0447	0.0343
Directa	Modelo Aditivo	0.0488	0.0488

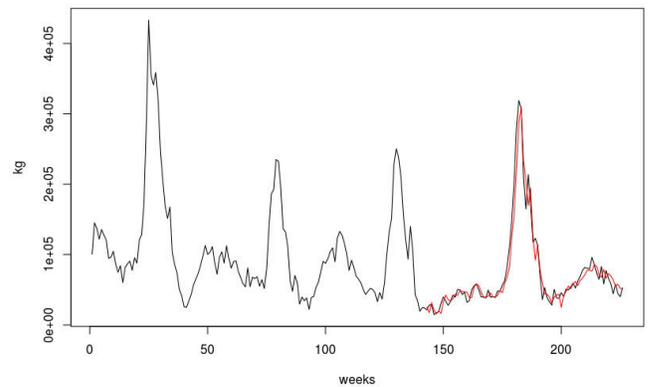
La mejora al emplear el enfoque con descomposición es considerable para el producto 1. El RMSE obtenido con nuestra metodología es de 0.0371, mientras que el menor RMSE obtenido con la metodología directa en cualquiera de sus variantes es de 0.0457 conseguido aplicando una red neuronal parcialmente recurrente. Para los ajustes con el resto de métodos en la metodología directa el RMSE es superior a 0.05 e incluso a 0.06. Por otro lado nuestra metodología obtiene un MAE más bajo de 0.0214, mientras que el menor MAE obtenido con la metodología directa es de 0.0331.

Mientras que para el producto 2 nuestra metodología ofrece también una mejor capacidad predictiva que la metodología directa. El RMSE más bajo obtenido con nuestro enfoque es del 0.0368 mientras que el menor de los RMSE obtenidos por el enfoque directo es de 0.0445, conseguido también con una red neuronal parcialmente recurrente. El resto de ajustes con el enfoque directo ofrecen un RMSE similar al 0.0445 conseguido por la red neuronal parcialmente recurrente, salvo varias excepciones. Con respecto al MAE el menor conseguido por nuestra metodología es de 0.0247, y el menor del enfoque directo es de 0.0292. El resto de variantes del enfoque directo obtienen un MAE superior al 0.03.

Así pues estos resultados muestran que tanto para el caso del producto 1 como el producto 2 los errores cometidos por nuestro enfoque son siempre menores que los errores obtenidos por el enfoque directo, siendo la mejora obtenida considerable.



(a) Producto 1



(b) Producto 2

Figura 1. Serie temporal de los kilogramos de producción real y predicción realizada por nuestra metodología (línea roja) en los casos de prueba para los dos productos analizados

## VI. CONCLUSIONES

En este trabajo se ha presentado una forma innovadora de realizar el análisis de una serie temporal del rendimiento de la producción de productos reales de una cooperativa hortofrutícola mediante la descomposición de la serie temporal general en sub-serie temporales según la semana de plantación, siendo el modelo predictivo final el resultado de la mezcla entre los mejores modelos ajustados para cada sub-serie a partir de un conjunto de métodos estadísticos y de Aprendizaje Automático. Además, esta metodología ha sido comparada con otra implementación posible del mismo problema.

Los resultados de los experimentos han mostrado que la metodología propuesta mejora la capacidad predictiva de la metodología comparada, ya que obtiene un error menor para ambos productos analizados. Además, siempre mejora el error obtenido en cada una de las comparaciones. Por lo que se puede concluir que una descomposición de la serie temporal según las semanas significativas de plantación se da lugar a



que se obtenga una mejora significativa en la predicción con respecto a la serie sin descomponer.

#### AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por los Proyectos de Investigación Nacional TIN2013-47210-P, y TIN2016-81113-R y por el Proyecto de Investigación de Excelencia de la Junta de Andalucía P12-TIC-2958.

#### REFERENCIAS

- [1] Akram, M., Bhatti, I., Ashfaq, M., Khan, A.A. *Hierarchical Forecasts of Agronomy-Based Data*, American Journal of Mathematical and Management Sciences, 36(1), 49-65, 2017
- [2] Bergmeir C. and Benítez J.M. *Neural Networks in R Using the Stuttgart Neural Network Simulator: RSNNS*. Journal of Statistical Software, 46(7), 1-26, 2012
- [3] Box G.E.P. and Jenkins G.M. *Time Series Analysis, Forecasting and Control*, 1970
- [4] Brdar S., Culibrk D., Marinkovic B., Crnobarac J., Crnojevic V. *Support Vector Machines with Features Contribution Analysis for Agricultural Yield Prediction*, Second International Workshop on Sensing Technologies in Agriculture, Forestry and Environment, 43-47, 2011
- [5] Choudhury, A. and Jones, J. *Crop yield prediction using time series models*, Journal of Economics and Economic Education Research., 15, 53-68, 2014.
- [6] Fukuda S., Spreer W., Yasunaga E., Yuge K., Sardud V. and Müller J. *Random Forests modelling for the estimation of mango (Mangifera indica L. cv. Chok Anan) fruit yields under different irrigation regimes*, Agricultural Water Management, 116(1), 142-150, 2013
- [7] Hastie T., Tibshirani R., Friedman, J. *The Elements of Statistical Learning*, Springer, New York, 2009.
- [8] Hyndman R.J. and Khandakar Y. *Automatic time series forecasting: the forecast package for R*. Journal of Statistical Software, 26(3), 1-22, 2008
- [9] Jeong J.H., Resop J., Mueller N., Fleisher D.H., Yun K., Butler E., Timlin D., Shim K., Gerber J., Reddy V., and Kim S.H. *Random Forests for Global and Regional Crop Yield Predictions*, PLoS One. 2016; 11(6): e0156571.
- [10] Ji, B., Sun Y., Yang S. and Wan J. *Artificial neural networks for rice yield prediction in mountainous regions*, Journal of Agricultural Science, 145: 249-26, 2007.
- [11] Karatzoglou A., Smola A., Hornik K. and Zeileis A. *kernlab - An S4 Package for Kernel Methods in R*. Journal of Statistical Software, 11(9), 1-20, 2004
- [12] Kaul M., Hill R.L., and Walthall C. *Artificial neural networks for corn and soybean yield prediction*, Agricultural Systems, 85(1): 1-18, 2005.
- [13] Liaw A. and Wiener M. *Classification and Regression by randomForest*. R News, 2(3), 18-22, 2002
- [14] Liu J., Goering C.E., and Tian L. *A neural network for setting target corn yields*, Transactions of the ASAE. Vol. 44(3): 705-713, 2007.
- [15] Najeeb I., Khuda B., Asif M. *Use of the ARIMA Model for Forecasting Wheat Area and Production in Pakistan*, Journal of Agriculture and Social Sciences, 1(2), 120-122, 2015
- [16] Ruß G. *Data Mining of Agricultural Yield Data: A Comparison of Regression Models*, In: Perner P. (eds) *Advances in Data Mining. Applications and Theoretical Aspects*, ICDM 2009. Lecture Notes in Computer Science, vol 5633.
- [17] Taylor S. and Letham B. *prophet: Automatic Forecasting Procedure. R package version 0.1*. 2017
- [18] Wuo W., Xue H. *An incorporative statistic and neural approach for crop yield modelling and forecasting*, Neural Computing and Applications, 21(1): 109-117, 2012.

# ¿Requiere la clasificación de series temporales métodos específicos?

Amaia Abanda<sup>1,2</sup>

<sup>1</sup> Basque Center for Applied Mathematics (BCAM)  
<sup>2</sup> Intelligent Systems Group (ISG)  
Department of Computer Science and Artificial Intelligence,  
University of the Basque Country UPV/EHU  
Bilbao, Spain  
aabanda@bcamath.org

Usue Mori<sup>2,3</sup>

<sup>2</sup> Intelligent Systems Group (ISG)  
Department of Computer Science and Artificial Intelligence  
<sup>3</sup> Department of Applied Mathematics  
Statistics and Operational Research  
University of the Basque Country UPV/EHU  
Bilbao, Spain  
usue.mori@ehu.es

Jose A. Lozano<sup>1,2</sup>

<sup>1</sup> Basque Center for Applied Mathematics (BCAM)  
<sup>2</sup> Intelligent Systems Group (ISG)  
Department of Computer Science and Artificial Intelligence,  
University of the Basque Country UPV/EHU  
Bilbao, Spain  
ja.lozano@ehu.eus

**Resumen**—La clasificación de series temporales tiene la peculiaridad, respecto a otros problemas de clasificación supervisada, de que las observaciones de las series o variables predictoras tienen un orden específico. La mayoría de las soluciones propuestas en la literatura consideran que este orden es discriminatorio para la clasificación y, por tanto, emplean métodos específicos que tienen en cuenta el orden. El objetivo de esta investigación es explorar, de una manera preliminar, si realmente es siempre necesario el uso de métodos específicos para series temporales o si hay algunos casos en los que los métodos de clasificación no específicos, habitualmente utilizados para datos de tipo convencional, obtienen mejores resultados que los específicos. La experimentación llevada a cabo en 40 bases de datos del repositorio UCR muestra como en los casos en los que el orden de las observaciones no es relevante para la clasificación, los clasificadores no específicos consiguen mejorar la precisión, mientras que en los casos en los que el orden es un factor clave no lo consiguen.

**Index Terms**—Clasificación, series temporales, orden, vector, información temporal, métodos específicos.

## I. INTRODUCTION

Una serie temporal es una secuencia de datos u observaciones que viene ordenada respecto al tiempo -la mayoría de las veces-, o respecto a otros aspectos como el espacio, por ejemplo. Es un tipo particular de datos precisamente porque tiene una naturaleza ordinal que la mayoría de datos no tienen. Las series temporales aparecen naturalmente en diferentes áreas como la bio-informática o economía [1], y están adquiriendo una gran relevancia en el ámbito del aprendizaje automático debido al gran reto que supone trabajar con este tipo especial de datos. De esta manera, continuamente están surgiendo nuevos métodos para representar, indexar, agrupar y clasificar

series temporales [2]. El presente trabajo se sitúa dentro del área de la clasificación de series temporales -Time Series Classification (TSC)-, donde cada serie del conjunto de entrenamiento tiene asociada una clase, y el objetivo es encontrar una función tal que, dada una serie nueva, sea capaz de predecir cuál es su clase. La diferencia principal con el problema clásico de clasificación es que, mientras en éstos las instancias vienen descritas por atributos sin orden específico, en la clasificación de series temporales las instancias vienen definidas por las propias series temporales completas [3][4]. Además de que las variables predictoras están ordenadas en este caso, las series pueden tener un número muy alto de observaciones, las longitudes pueden ser variables dentro de una misma base de datos y, dependiendo del contexto, pueden ser observaciones con mucho ruido [5].

La peculiaridad de las series temporales, su posible interpretabilidad y su significado semántico han llevado a la comunidad científica a asumir que éstas tienen que ser tratadas con métodos específicamente diseñados para series [4][6][7][8]. Estos métodos tienen en cuenta la información temporal que intrínsecamente contienen las series para extraer atributos, construir modelos, medidas de similitud, etc. útiles para la clasificación. El orden de las observaciones ha sido hasta ahora una de las características más comúnmente asumidas como información temporal discriminatoria; en los métodos basados en distancias elásticas [3][9][10], en los métodos basados en modelos autorregresivos [11][12] en los modelos ocultos de Markov [13], o en los métodos extraen atributos temporales de las series [5].

Esta asunción implica que los métodos no específicos, es decir, los métodos basados en clasificadores tradicionales



que no tienen en cuenta la información temporal, no deberían ser competitivos con los específicos en cuanto a precisión se refiere. En este trabajo se pretende explorar hasta qué punto esta afirmación es cierta y, sobre todo, en qué casos se cumple o no se cumple.

Este trabajo parte de la clasificación de series temporales basada en distancias [14], donde se utiliza la distancia/similitud entre series como criterio para la clasificación; dos series que sean similares pertenecerán a la misma clase. En particular, el método que hasta ahora más se ha utilizado para en la clasificación de series temporales basada en distancias es el 1-Nearest Neighbour (1NN), clasificador que aunque haya demostrado buenos resultados en el ámbito [2][9][15][16], no es muy robusto. En cuanto a las distancias utilizadas, en el ámbito de la clasificación de series temporales, podemos distinguir entre distancias que tienen en cuenta el orden de las observaciones y distancias que no lo tienen, pero muchas de las distancias situadas en el segundo grupo son muy costosas computacionalmente. En este contexto, sería interesante saber en qué casos no es necesario el uso de métodos específicos -casos en los que se podrían utilizar clasificadores estándares de una manera eficiente y con mejores resultados-.

El trabajo se organiza de la siguiente forma: en la Sección II se introducen algunos conceptos básicos para contextualizar la clasificación de series temporales basada en distancias, en la Sección III se presenta la propuesta y la experimentación realizada y, finalmente, en la Sección IV presentamos las principales conclusiones obtenidas.

## II. CONCEPTOS BÁSICOS Y MOTIVACIÓN

En esta sección se presenta un breve resumen de los conceptos básicos necesarios para abordar la clasificación de series temporales basada en distancias y se introducen algunas de las distancias más conocidas para series.

### II-A. Clasificación de series temporales

Los métodos de clasificación de series temporales se pueden dividir entre tres principales categorías [15]: métodos basados en atributos, basados en modelos y basados en distancias. Dentro de la primera línea, los investigadores tratan de extraer características fundamentales de las series para obtener una nueva representación no-ordenada y de menor dimensión que, además, contenga la información más relevante de las series. Esta transformación evita tener que aprender directamente con las series originales y las traslada a un nuevo espacio donde las características discriminatorias pueden ser más detectables [17]. Algunos ejemplos de estas representaciones incluyen Discrete Fourier Transformation (DFT) [5], Discrete Wavelet Transformation (DWT) [18] o Piecewise Aggregate Approximation (PAA) [19]. Por otro lado, en los métodos basados en modelos, se asume que todas las series de una clase han sido generadas por un modelo subyacente y a una serie nueva se le asigna la clase del modelo al que mejor se ajuste. Algunos de los modelos más utilizados son los

modelos auto-regresivos [11] [12] o los modelos ocultos de Markov [13]. Por último, en los métodos basados en distancias los investigadores tratan de definir una similitud, o disimilitud, entre series que tenga en cuenta diferentes características semánticas o temporales. La definición de una distancia adecuada es una cuestión crucial, ya que cada distancia refleja diferentes características de las series. Una vez elegida la distancia adecuada, la clasificación se lleva a cabo empleando métodos basados en distancias, en la mayoría de los casos clasificadores basados en el vecino más cercano (1NN). Entre las distancias para series temporales más conocidas están la distancia Euclídea, Dynamic Time Warping (DTW) [20] o Edit Distance with RealPenalty (ERP) [21].

### II-B. Distancias de series temporales

Las distancias entre series temporales suelen categorizarse habitualmente en dos grupos principales mostradas en la Figura 1 [22]; las *medidas rígidas*, que se refieren a aquellas medidas que comparan el punto  $i$ -ésimo de una serie con el punto  $i$ -ésimo de la otra, y las *medidas elásticas*, que tratan de crear un mapeo no lineal entre las series para alinearlas, permitiendo una comparación de uno-a-varios puntos. La mayor diferencia entre estos dos tipos de medidas es que las medidas rígidas, al no considerar los puntos de alrededor, tratan la serie como si fuera un vector y por tanto, no consideran la ordenación de las mediciones. De esta forma, aún desordenando la serie, obtendríamos los mismos resultados de clasificación. Las medidas elásticas, por el contrario, consideran que el orden de las observaciones es determinante y hacen uso de la misma en su cálculo. Por tanto, otra ordenación de las observaciones podría cambiar por completo los resultados de la clasificación.

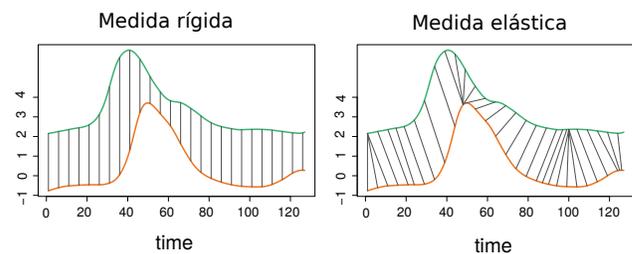


Figura 1: Alineamientos de medidas rígidas y elásticas

La distancia rígida más habitual es la denominada distancia Euclídea. Se define de la siguiente forma: dadas dos series temporales  $T=(t_1, \dots, t_n)$  y  $S=(s_1, \dots, s_n)$ ,

$$ED(T, S) = \sqrt{\sum_{i=1}^n (t_i - s_i)^2}$$

Esta distancia es ampliamente conocida debido que cumple buenas propiedades, como ser métrica, así como su bajo coste computacional y simplicidad, razones por las

que es habitualmente utilizada en numerosos problemas de aprendizaje automático. Sin embargo, tiene también algunos inconvenientes como que sólo acepta dos series que tengan la misma longitud, o como se ha comentado anteriormente, que no considera el orden de las observaciones.

En vista de las carencias de la distancia Euclídea, en los últimos años se han presentado numerosas distancias elásticas específicamente diseñadas para medir la disimilitud entre series temporales. La más habitual entre ellas es la Dynamic Time Warping (DTW). Esta distancia alinea las dos series con tal de minimizar la distancia entre ellas y, por lo tanto, es robusta frente a desfases y distorsiones en el tiempo. Además, a diferencia de la distancia Euclídea, permite calcular la distancia entre series de diferentes longitudes. Dadas dos series temporales  $T$  y  $S$ , el objetivo de la DTW es buscar la alineación óptima que minimice la distancia entre ellas. Para ello, el primer paso es construir una matriz de distancias de  $n \times m$  donde cada posición  $(i, j)$  contiene la distancia  $(t_i - s_j)^2$ , que representa el coste de alinear la observación  $i$ -ésima de  $T$  con la observación  $j$ -ésima de  $S$ . Así, un alineamiento entre dos series se define como un camino  $\pi$  en la matriz de distancias, que tiene que cumplir ciertas restricciones (continua, monótona creciente y puntos de inicio y final fijos) (ver Figura 2). El alineamiento óptimo entre dos series es aquel que minimiza la distancia acumulativa. Finalmente, la distancia  $DTW(T, S)$  se define como la distancia acumulativa del camino óptimo entre  $T$  y  $S$ . En la práctica, este camino óptimo se encuentra mediante métodos de programación dinámica [23] y uno de las mayores desventajas de ésta distancia es que este proceso tiene un coste computacional de  $\mathcal{O}(N^2)$ , siendo  $N$  el número de series.

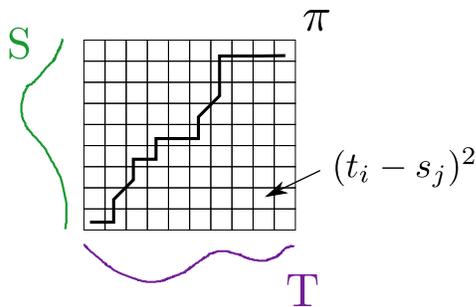


Figura 2: Matriz de distancias y camino óptimo de DTW

La mayoría de los métodos de clasificación de series temporales asumen que el orden de las observaciones es fundamental para discriminar entre clases y emplean medidas elásticas como la DTW [24][16][10]. El objetivo de este trabajo es realizar un estudio preliminar para explorar si realmente es, o en qué casos, la información temporal -en particular, el orden de las observaciones- fundamental para la clasificación. Esta cuestión proporcionaría información importante sobre la utilidad de clasificadores específicos

para series temporales, ya que si el orden de las observaciones no es relevante, no habría necesidad de usar métodos específicos -clasificadores basados en la temporalidad-, sino que las series podrían entenderse como simples vectores y podrían utilizarse también otros clasificadores clásicos, obteniendo quizás resultados mejores.

### III. PROPUESTA Y EXPERIMENTACIÓN

Como hemos expuesto anteriormente, el objetivo de este trabajo es explorar si realmente la información temporal y, en particular, el orden de las observaciones, juega siempre un papel fundamental en la clasificación de series temporales. Además, la hipótesis principal es que en aquellos casos donde el orden no es discriminatorio, los clasificadores no específicos podrían funcionar mejor, debido a que son más complejos y robustos que el 1-NN. Es decir, en los casos donde el orden no es relevante, las series pueden ser interpretadas como vectores (*feature vectors*) y, por tanto, las observaciones puede entenderse como dimensiones que no tienen un orden pre-definido. En los casos donde el orden es un aspecto discriminatorio para la clasificación, el hecho de que cada observación esté en una posición concreta es relevante y por tanto no se pueden interpretar las series como vectores. Los clasificadores no específicos, o tradicionales, esperan como entrada un vector sin orden, por lo que en el primer caso podrían funcionar bien mientras que en el segundo, al no ser capaces de tener en cuenta el orden, deberían obtener peores resultados.

El estudio parte de la clasificación basada en distancias y, más particularmente, tomamos el clasificador 1-NN como referencia. Como distancia que no considera el orden de las observaciones se utiliza la distancia Euclídea, mientras que como distancia que sí considera el orden consideraremos la DTW.

Asumiremos que en los casos en los que la distancia Euclídea obtiene mayor precisión que la DTW, el orden de las observaciones no es relevante para la discriminación, mientras que en las que la distancia DTW obtiene mayor precisión sí lo es. El objetivo es explorar si en los casos en los que 1-NN-EUC (método no específico) tiene mayor precisión que el 1-NN-DTW (método específico), los clasificadores estándares (métodos no específicos), como el Support Vector Machine o naive Bayes, mejoran más (veces) los resultados que en los casos en los que el 1-NN-DTW tiene mayor precisión que el 1-NN-EUC. En particular, se quiere comprobar si, en el caso de que el 1-NN-EUC obtiene mejores resultados que el 1-NN-DTW, los clasificadores estándares pueden llegar a mejorar los resultados obtenidos con el 1-NN.

Con el objetivo de poder contrastar las hipótesis planteadas, la clasificación se ha llevado a cabo utilizando, por un lado, 1-NN-Euclídea y 1-NN-DTW y, por otro, 3 clasificadores estándares (no específicos): Support Vector Machine (SVM), naive Bayes (NB) y Random Forest (RF). No se han ajustado los parámetros de ninguno para poder establecer una base de referencia. Los experimentos se han



realizado con 40 bases de datos del repositorio de series temporales UCR [25], un repositorio de bases de datos de series temporales que es habitualmente utilizada como referencia para evaluar nuevos métodos de clasificación de series temporales.

En el Cuadro I se muestran los resultados de la clasificación de las bases de datos donde el 1-NN-EUC obtiene mayor precisión que el 1-NN-DTW (15/40), mientras que en el Cuadro II la de aquellas en las que el 1-NN-DTW obtiene mayor precisión que 1-NN-EUC (25/40). Estas proporciones eran de esperar debido a que el 1-NN-DTW se considera uno de los métodos que mejores resultados obtienen en la clasificación de series temporales [2][9][16][15]. Se han separado las bases de datos en estas dos tablas para poder visualizar mejor si hay una tendencia diferente en cada uno de los casos.

En el primer cuadro, donde el método no específico obtiene mejores resultados que el específico, se puede observar que los clasificadores estándares superan en algunos casos (12/15) al 1-NN. En el segundo cuadro, en cambio, donde el método específico funciona mejor que el no específico, los clasificadores estándares no superan al 1-NN en casi ningún caso (6/25).

BBDD	EUC	DTW	SVM	NB	RF
Adiac	0.61	0.52	0.40	0.57	<b>0.64</b>
Beef	0.53	0.50	0.50	0.47	<b>0.57</b>
Chlothe	0.65	0.62	0.58	0.35	<b>0.71</b>
CinC	0.90	0.69	0.73	0.88	0.76
ECG	0.88	0.80	0.87	0.77	0.83
ECGF5	0.80	0.75	<b>0.84</b>	0.78	<b>0.80</b>
GunPoint	0.91	0.89	0.81	0.78	<b>0.92</b>
Haptics	0.37	0.35	<b>0.45</b>	<b>0.44</b>	<b>0.46</b>
SonyAI	0.70	0.66	<b>0.78</b>	<b>0.94</b>	0.68
SonyAI II	0.86	0.82	0.82	0.79	0.80
Swedish	0.79	0.75	<b>0.88</b>	<b>0.86</b>	<b>0.88</b>
WaveX	0.74	0.73	<b>0.76</b>	0.66	<b>0.76</b>
WaveY	0.66	0.64	<b>0.67</b>	0.56	<b>0.69</b>
Wafer	0.99	0.98	<b>0.99</b>	0.70	<b>0.99</b>
FetalECG2	0.88	0.83	<b>0.90</b>	0.83	<b>0.91</b>

Cuadro I: Resultados de clasificación de las bases de datos donde 1-NN-Euc obtiene mayor precisión que 1-NN-DTW.

Con fin de entender mejor los resultados, el Cuadro III sintetiza y compara los dos cuadros anteriores. En él se refleja para cada una de las tablas (representadas por las filas EUC y DTW) el número de veces en el que al menos uno -y al menos dos- de los clasificadores no-específicos empleados supera la precisión del 1-NN. Se puede apreciar que en los casos del Cuadro I (fila EUC), los métodos no-específicos tienden a superarlo al menos una vez en el 80% de los casos, mientras que los casos del Cuadro II (fila DTW), este porcentaje baja hasta el 24%. Lo mismo sucede si contamos las veces en las que los métodos no-específicos superan al menos 2 veces al 1NN: el valor es 53% para las bases de datos donde la Euclídea funciona mejor y 4% para las del DTW.

Por lo tanto, se puede apreciar una tendencia a que los

BBDD	EUC	DTW	SVM	NB	RF
50Words	0.63	0.71	0.62	0.58	0.66
CBF	0.85	0.97	0.87	0.90	0.91
Coffee	0.75	0.79	0.71	0.68	0.68
Cricket_X	0.57	0.73	0.54	0.44	0.62
Cricket_Y	0.64	0.75	0.63	0.53	0.74
Cricket_Z	0.62	0.73	0.58	0.42	0.66
Diatom	0.93	0.96	0.90	0.87	0.91
Face_all	0.71	0.75	0.74	0.69	<b>0.81</b>
Face_four	0.78	0.84	0.64	<b>0.90</b>	0.77
FacesUCR	0.77	0.92	0.73	0.74	0.79
Fish	0.78	0.85	0.78	0.66	0.79
InlineSkate	0.34	0.38	0.25	0.22	0.35
Lightning2	0.75	0.80	0.70	0.67	0.75
Lightning7	0.58	0.77	0.63	0.71	0.75
MALLAT	0.91	0.92	0.77	0.87	<b>0.93</b>
MedicalImg	0.68	0.73	0.57	0.44	<b>0.73</b>
MoteStrain	0.88	0.90	0.85	0.84	0.89
OSU Leaf	0.52	0.63	0.52	0.38	0.51
Symbols	0.90	0.95	0.76	0.64	0.87
Synthetic	0.88	0.95	0.98	<b>0.96</b>	<b>0.96</b>
Trace	0.76	0.99	0.71	0.80	0.86
Two Lead	0.75	0.93	0.72	0.69	0.73
Two Patterns	0.91	0.99	0.89	0.46	0.85
WaveY	0.65	0.65	0.70	0.56	<b>0.71</b>
WordSyn	0.62	0.67	0.53	0.48	0.57

Cuadro II: Resultados de clasificación de las bases de datos donde 1-NN-Dtw obtiene mayor precisión que 1-NN-Euc.

métodos no-específicos funcionen mejor en los casos en los que la distancia Euclídea funciona mejor que la DTW con el 1-NN. Es decir, en las bases de datos en las que el orden de las observaciones no es relevante para clasificar y los métodos no-específicos -que no tienen en cuenta el orden- funcionan mejor que en las bases de datos que en las que el orden si es relevante.

	$\geq 1$ vez	$\geq 2$ veces
EUC	12/15 = 80%	8/15 = 53%
DTW	6/25 = 24%	1/25 = 4%

Cuadro III: Comparativa de las veces que los clasificadores estándares superan el 1-NN en el método no específico (EUC) y específico (DTW).

Para evaluar estadísticamente los Cuadros I y II, se han realizado múltiples test estadísticos emparejados de Wilcoxon utilizando el paquete 'scmamp' [26] para R. En el primer caso, se ha realizado 3 test estadísticos para comprobar si hay diferencias significativas entre los métodos del Cuadro I. En particular, se han comparado las siguientes columnas: 1-NN-EUC con SVM, 1-NN-EUC con NB y 1-NN-EUC con RF. Después de corregir los p-valores obtenidos de cada uno de ellos (0.34, 0.09 y 0.28, correspondientemente), no podemos rechazar la hipótesis nula y, por tanto, no podemos afirmar que haya diferencias estadísticas de que los métodos no-específicos y el 1-NN tengan un comportamiento diferente. En el segundo caso, se han comparado los resultados de los métodos del Cuadro II; en particular, comparando el 1-NN-DTW con SVM,

1-NN-DTW con NB y 1-NN-DTW con RF. Después de corregir los p-valores obtenidos (0.00004, 0.00004 y 0.0008) podemos rechazar la hipótesis nula y afirmar que hay diferencias significativas entre los métodos. En particular, podemos afirmar que los métodos no-específicos tienen peores resultados de clasificación que el 1-NN-DTW. Resumiendo, en los casos donde la distancia Euclídea funciona mejor que la DTW (el orden no tiene importancia), los métodos no-específicos se comportan parecido al 1-NN, mientras que en los casos donde la DTW funciona mejor (el orden sí tiene importancia), funcionan peor que el 1-NN.

Para terminar, se ha realizado otros 2 test estadísticos para comparar si hay diferencias significativas entre los resultados del 1-NN y el mejor de los 3 métodos no-específicos en cada caso (Cuadro IV). En ambos casos, los test afirman que hay diferencias significativas con p-valores 0.01 y 0.002. En los casos donde el 1-NN-EUC obtiene mejores resultados que el 1-NN-DTW, el test indica que al menos uno de los 3 métodos no-específicos obtiene mejores resultados que el 1-NN. En los casos donde el 1-NN-DTW obtiene mejores resultados que el 1-NN-EUC, por el contrario, el test muestra que los 3 métodos específicos obtienen peores resultados que el 1-NN.

BBDD	EUC	Mejor	BBDD	DTW	Mejor
Adiac	0.61	<b>0.64</b>	50Words	0.71	0.66
Beef	0.53	<b>0.57</b>	CBF	<b>0.97</b>	0.91
Chlothe	0.65	<b>0.71</b>	Coffee	<b>0.79</b>	0.71
CinC	<b>0.90</b>	0.88	Cricket_X	<b>0.73</b>	0.62
ECG	<b>0.88</b>	0.87	Cricket_Y	<b>0.75</b>	0.74
ECGF5	0.80	<b>0.84</b>	Cricket_Z	<b>0.73</b>	0.66
GunPoint	0.91	<b>0.92</b>	Diatom	<b>0.96</b>	0.91
Haptics	0.37	<b>0.46</b>	Face_all	0.75	<b>0.81</b>
SonyAI	0.70	<b>0.94</b>	Face_four	0.84	<b>0.90</b>
SonyAI II	<b>0.86</b>	0.82	FacesUCR	<b>0.92</b>	0.79
Swedish	0.79	<b>0.88</b>	Fish	<b>0.85</b>	0.79
WaveX	0.74	<b>0.76</b>	InlineSkate	<b>0.38</b>	0.35
WaveY	0.66	<b>0.69</b>	Lightning2	<b>0.80</b>	0.75
Wafer	<b>0.99</b>	<b>0.99</b>	Lightning7	<b>0.77</b>	0.75
FetalECG2	0.88	<b>0.91</b>	MALLAT	<b>0.92</b>	0.93
			MedicalImg	<b>0.73</b>	<b>0.73</b>
			MoteStrain	<b>0.90</b>	0.89
			OSU Leaf	<b>0.63</b>	0.52
			Symbols	<b>0.95</b>	0.87
			Synthetic	0.95	<b>0.98</b>
			Trace	<b>0.99</b>	0.86
			Two Lead	<b>0.93</b>	0.73
			Two Patterns	<b>0.99</b>	0.89
			WaveY	0.65	<b>0.71</b>
			WordSyn	<b>0.67</b>	0.57

Cuadro IV: Resultados de clasificación del 1-NN y el mejor de los 3 clasificadores estándares en cada base de datos.

#### IV. CONCLUSIONES

En este trabajo el objetivo era explorar de una manera preliminar si realmente es necesario siempre utilizar los métodos específicos que tienen en cuenta la información temporal, en particular, el orden de las observaciones, para la clasificación de series temporales. La mayoría de los

métodos habitualmente utilizados en clasificación de series temporales, especialmente aquellos basados en distancias, asumen, por defecto, que el orden es un factor discriminatorio para la clasificación y que, por tanto, interpretar las series como vectores sin orden no aportaría beneficios. Esta cuestión limita el uso de clasificadores estándares que no están basados en la temporalidad (por ejemplo SVM, naive Bayes o Random Forest), ya que si el orden de las series es crucial, utilizar estos clasificadores que no lo tienen en cuenta no tendría sentido. Sin embargo, la hipótesis de este estudio es que no hay que asumir siempre que el orden es discriminatorio y hay casos en los que los clasificadores estándares pueden funcionar igual o mejor que el tan valorado 1-NN.

Para evaluar esta hipótesis se han tomado como métodos de referencia el 1-NN-EUC (que no tiene en cuenta el orden de las observaciones) y el 1-NN-DTW (que sí tiene en cuenta el orden de las observaciones). De esta manera, en la experimentación se observa que en los casos donde el 1-NN-EUC obtiene mejores resultados que el 1-NN-DTW, los clasificadores estándares pueden mejorar la precisión de clasificación (en el 80% de los casos), mientras que en los otros casos los clasificadores estándares no consiguen mejorarlo (solo en el 24% de los casos lo hacen).

Este resultado era esperado ya que si en una base de datos el 1-NN-EUC obtiene mayor precisión que el 1-NN-DTW se puede suponer que el orden de las observaciones no es un factor determinante para la clasificación. En ese caso, los clasificadores estándares, que son más complejos y robustos que el 1-NN, y no tienen en cuenta el orden, deberían funcionar bien. Por otro lado, si en una base de datos el 1-NN-DTW obtiene mayor precisión que el 1-NN-EUC se puede interpretar que el orden de las observaciones sí es un factor determinante para la clasificación, y tiene sentido que los clasificadores estándares, que no tienen en cuenta el orden de las observaciones, rindan peor. De hecho, los test estadísticos realizados a los resultados confirman las hipótesis. En otras palabras, cuando el orden de las observaciones no es un factor discriminatorio, los clasificadores estándares mejoran el resultado del 1-NN, mientras que cuando el orden es sí es relevante no lo consiguen.

En conclusión, no es que los clasificadores estándares, y métodos no específicos en general, sean inadecuados para la clasificación de series temporales, si no que dependiendo de las características discriminatorias de cada base de datos (en particular, la relevancia del orden de las observaciones para la clasificación), pueden llegar a ser beneficiosos. Por ello, sería interesante entender más en profundidad cuáles son las características temporales discriminatorias de las series, seguir estudiando la importancia del orden para la clasificación y buscar otras maneras de evaluar la influencia de este factor. Además, sería también enriquecedor seguir explorando el uso de clasificadores estándares, o métodos no específicos, para series temporales, ya que son mucho más robustos que el



1-NN y dependiendo de la distancia empleada en el 1-NN, mucho más rápidos.

#### AGRADECIMIENTOS

Esta investigación esta subvencionada por el Gobierno Vasco a través del programa BERC 2018-2021, así como del Ministerio de Economía y Competitividad (MINECO) mediante la acreditación de excelencia BCAM Severo Ochoa SEV-2013-0323. También del proyecto TIN2017-82626-R, financiado por AEI/FEDER (UE) y acrónimo “GECECPAST”. Además, gracias al Programa de Grupos de Investigación 2013-2018 (IT-609-13) (Gobierno Vasco) y TIN2016-78365-R (MINECO). A. Abanda está subvencionada con la beca BES-2016-076890.

#### REFERENCIAS

- [1] E. Keogh and S. Kasetty, “On the need for time series data mining benchmarks,” *Proceedings of the 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, p. 102, 2002. [Online]. Available: <http://dl.acm.org/citation.cfm?id=775047.775062>
- [2] P. Esling and C. Agon, “Time-series data mining,” *ACM Computing Surveys*, vol. 45, no. 1, pp. 1–34, 2012. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2379776.2379788>
- [3] A. Bagnall, J. Lines, A. Bostrom, J. Large, and E. Keogh, “The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances,” *Data Mining and Knowledge Discovery*, vol. 31, no. 3, pp. 606–660, 2017.
- [4] T. C. Fu, “A review on time series data mining,” *Engineering Applications of Artificial Intelligence*, vol. 24, no. 1, pp. 164–181, 2011. [Online]. Available: <http://dx.doi.org/10.1016/j.engappai.2010.09.007>
- [5] C. Faloutsos, M. Ranganathan, and Y. Manolopoulos, “Fast subsequence matching in time-series databases,” *ACM SIGMOD International Conference on Management of Data*, pp. 419–429, 1994.
- [6] M. Cuturi and J. Vert, “A kernel for time series based on global alignments,” *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 1, pp. 413–416, 2007. [Online]. Available: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=4217433](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4217433)
- [7] R. Povinelli, “Time series classification using Gaussian mixture models of reconstructed phase spaces,” *Knowledge and Data ...*, vol. 16, no. 6, pp. 779–783, 2004. [Online]. Available: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=1294898](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1294898)
- [8] D. Eads, D. Hill, S. David, S. Perkins, J. Ma, R. Porter, and J. Theiler, “Genetic Algorithms and Support Vector Machines for Time Series Classification,” *Applications and Science of Neural Networks, Fuzzy Systems, and Evolutionary Computation*, vol. 4787, 2002.
- [9] X. Wang, A. Mueen, H. Ding, G. Trajcevski, P. Scheuermann, and E. Keogh, “Experimental comparison of representation methods and distance measures for time series data,” *Data Mining and Knowledge Discovery*, vol. 26, no. 2, pp. 275–309, 2013.
- [10] J. Lines and A. Bagnall, “Time series classification with ensembles of elastic distance measures,” *Data Mining and Knowledge Discovery*, vol. 29, no. 3, pp. 565–592, 2015.
- [11] A. Bagnall and Gareth Janacek, “A run length transformation for discriminating between auto regressive time series,” *Journal of Classification*, vol. 31, no. October, pp. 274–295, 2014.
- [12] M. Corduas and D. Piccolo, “Time series clustering and classification by the autoregressive metric,” *Computational Statistics and Data Analysis*, vol. 52, no. 4, pp. 1860–1872, 2008.
- [13] P. Smyth, “Clustering sequences with hidden Markov models,” *Advances in Neural Information Processing Systems*, vol. 9, pp. 648–654, 1997. [Online]. Available: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.44.3648>
- [14] A. Abanda, U. Mori, and J. A. Lozano, “A review on distance based time series classification,” <https://arxiv.org/abs/1806.04509>, pp. 1–28, 2018. [Online]. Available: <http://arxiv.org/abs/1806.04509>
- [15] Z. Xing, J. Pei, and E. Keogh, “A brief survey on sequence classification,” *ACM SIGKDD Explorations Newsletter*, vol. 12, no. 1, p. 40, 2010. [Online]. Available: <http://portal.acm.org/citation.cfm?doid=1882471.1882478>
- [16] Y. Chen, B. Hu, E. Keogh, and G. E. Batista, “DTW-D: Time Series Semi-Supervised Learning from a Single Example,” *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, p. 383, 2013. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2487575.2487633>
- [17] A. Bagnall, J. Lines, J. Hills, and A. Bostrom, “Time-series classification with COTE: The collective of transformation-based ensembles,” *Proceedings of 32nd ICDE International Conference on Data Engineering*, vol. 27, no. 9, pp. 1548–1549, 2016.
- [18] I. Popivanov and R. J. Miller, “Similarity Search Over Time-Series Data Using Wavelets,” *Proceedings 18th International Conference on Data Engineering (ICDE)*, pp. 212–221, 2002.
- [19] E. Keogh, K. Chakrabarti, M. Pazzani, and S. Mehrotra, “Dimensionality Reduction for Fast Similarity Search in Large Time Series Databases,” *Knowledge and Information Systems*, vol. 3, no. 3, pp. 263–286, 2001. [Online]. Available: <http://link.springer.com/10.1007/PL00011669>
- [20] D. Berndt and J. Clifford, “Using dynamic time warping to find patterns in time series,” *Workshop on Knowledge Knowledge Discovery in Databases*, vol. 398, pp. 359–370, 1994. [Online]. Available: <http://www.aaai.org/Papers/Workshops/1994/WS-94-03/WS94-03-031.pdf>
- [21] L. Chen and R. Ng, “On The Marriage of Lp-norms and Edit Distance,” in *International conference on Very large data bases*, 2004, pp. 792–803.
- [22] H. Kaya and . Gündüz-Ö üdücü, “A distance based time series classification framework,” *Information Systems*, vol. 51, pp. 27–42, 2015.
- [23] H. Sakoe and S. Chiba, “Dynamic Programming Algorithm Optimization for Spoken Word Recognition,” *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 26, no. 1, pp. 43–49, 1978.
- [24] X. Xi, E. Keogh, C. Shelton, L. Wei, and C. A. Ratanamahatana, “Fast time series classification using numerosity reduction,” *Proceedings of the 23rd ICML International Conference on Machine learning*, pp. 1033–1040, 2006. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1143974>
- [25] Y. Chen, E. Keogh, B. Hu, N. Begum, A. Bagnall, A. Mueen, and G. E. Batista, “The UCR Time Series Classification Archive,” 2015. [Online]. Available: [www.timeseriesclassification.com](http://www.timeseriesclassification.com)
- [26] B. Calvo and G. Santafe, “scmamp: Statistical comparison of multiple algorithms in multiple problems,” *The R Journal*, vol. Accepted for publication, 2015.

# Reglas de Asociación en Flujos de Datos para Monitorizar Actividad de Teléfonos Móviles

Elena Ruiz, Jorge Casillas

DaSCI (Centro de Investigación en Ciencia  
de Datos e Inteligencia Computacional)  
Universidad de Granada, Granada, España  
Email: {eruiz, casillas}@decsai.ugr.es

**Abstract**—Los algoritmos de minería de flujo de datos trabajan sobre datos con altas tasas de llegada, que evolucionan a lo largo del tiempo y requieren respuesta en tiempo real. Este tipo de técnicas, que procesan los datos al vuelo, han captado la atención tanto del ámbito científico como del industrial. El aprendizaje descriptivo en flujos de datos nos permite tener un modelo que se adapta a la evolución de los datos para explicar qué está pasando en tiempo real. En este trabajo, mostramos el potencial de este campo usando información real registrada a través de teléfonos móviles durante meses (por el MIT Human Dynamics Lab). El objetivo es evolucionar de forma dinámica reglas de asociación que expliquen la actividad del usuario en cualquier momento de forma muy eficiente para que pueda incorporarse en un dispositivo móvil. Para conseguir este objetivo empleamos un algoritmo evolutivo que aprende y mantiene de forma incremental una población de reglas de asociación.

**Keywords**—reglas de asociación; flujo de datos; algoritmo genético; aprendizaje automático; aprendizaje online

## I. INTRODUCCIÓN

Vivimos en la era de los datos, donde todos nuestros movimientos y actividades son registrados (o podrían serlo) y, a veces, almacenados y procesados. Obviamente, una gran parte de la información generada carece de interés. Elegir qué información es relevante, sintetizarla y extraer conocimiento de ella es, cada vez, un aspecto más crítico en la sociedad actual. En ocasiones es posible utilizar esta información para obtener modelos (data mining) que simplifican la compleja realidad que contiene dicha información.

La necesidad de extraer información relevante de fuentes de datos ordenados cronológicamente en forma de un flujo continuo, veloz y que cambia con el tiempo, excediendo las capacidades habituales de almacenamiento y procesamiento son cada vez más comunes tanto en el entorno industrial como en el científico [1]. Para solucionar este tipo de problemas es posible gestionar flujos de datos, secuencias infinitas de registros estructurados que se reciben de forma continua [1]. La característica clave de estos sistemas es que los datos producidos por estos flujos no se almacenan de forma permanente, sino que se procesan sobre la marcha. Cada dato es analizado, procesado y olvidado, haciendo posible la gestión de grandes

cantidades de datos en tiempo real, incluso con capacidades de almacenamiento y procesamiento reducidas.

Los principales problemas de aprendizaje estudiados en la minería de flujo de datos [1], [2] son: (1) clasificación [3], (2) clustering [4] y (3) patrones frecuentes. En los últimos años, la mayor parte de la literatura especializada en este área se ha centrado en clasificación (y *concept-drift*); a pesar de su falta de aplicabilidad en casos reales, lo que ha derivado en experimentaciones basadas únicamente en benchmarks y datos sintéticos. Sería más realista generar modelos descriptivos e interpretables que permitan monitorear sistemas.

En general, el aprendizaje no supervisado es más directamente aplicable a problemas reales de flujo de datos, por lo que el clustering incremental ha experimentado un desarrollo significativo. Sin embargo, el conocimiento que se descubre (segmentación) resulta a menudo insuficiente para ayudar en la toma de decisiones. Por lo tanto, el descubrimiento de patrones frecuentes y reglas de asociación se considera una muy buena manera de abordar muchos problemas de flujo de datos cuyo propósito consiste en supervisar o monitorear (no predecir) en tiempo real usando modelos independientes, significativos, legibles y simples. Más concretamente, el descubrimiento de asociaciones en flujos de datos mediante la producción de reglas de asociación en un proceso completamente on-line, es particularmente interesante debido a: (1) la demanda de interpretabilidad de los patrones descubiertos en los datos, (2) la necesidad de descubrir patrones a medida que suceden, y (3) los altos y continuos volúmenes de datos a procesar, que exigen algoritmos escalables. Un caso real que supone un buen ejemplo de la utilidad de este campo es la detección de amenazas potenciales para los sitios web y las infraestructuras de red [5]. Existen otras estrategias de detección de anomalías (estadísticas o basadas en densidad), pero típicamente se basan en datos etiquetados y, por lo tanto, no se adaptan a nuevos conceptos. Otro posible caso de uso es el analizado en este documento, en el que se trabaja sobre distintos tipos de información relacionada con el uso del teléfono móvil.

El objetivo de este trabajo es mostrar el potencial de la minería de reglas de asociación en flujo de datos al tratar con varios meses de datos reales de uso de teléfonos móviles (tasa de muestreo de un minuto) proporcionados por el MIT Media Lab. El objetivo final es mantener dinámicamente un conjunto de reglas de asociación que expliquen la actividad del usuario

Este trabajo ha sido financiado por los fondos MINECO/FEDER (TIN2017-89517-P), y por el Proyecto BigDaP-TOOLS - Ayudas Fundación BBVA a Equipos de Investigación Científica 2016. E. Ruiz disfruta de un contrato vinculado al proyecto TIN2014-57251-P del MINECO.



en cualquier momento de forma muy eficiente.

El resto de este documento está organizado de la siguiente manera: La sección II presenta las principales características de Fuzzy-CSar (el algoritmo utilizado en este estudio). La sección III proporciona una descripción del estudio realizado por los investigadores del MIT y explica el proceso de preparación que hemos aplicado a los datos. La sección IV presenta los resultados obtenidos. Finalmente, la Sección V resume y concluye el trabajo.

## II. FUZZY-CSAR

Fuzzy-CSar [6] está diseñado para extraer reglas de asociación difusas de flujos de datos mediante la combinación de un algoritmo genético (GA) y mecanismos de aportación de crédito de forma on-line. Es uno de los pocos algoritmos capaces de generar directamente reglas de asociación (no solo *itemsets* frecuentes) con atributos tanto cuantitativos como cualitativos de forma puramente on-line, sin emplear ventana deslizante ni ninguna otra técnica para almacenar datos. Gracias a estas propiedades, el algoritmo encaja perfectamente con el propósito de este trabajo.

Fuzzy-CSar mantiene una población de individuos, donde cada uno está representado por una regla de asociación difusa y un grupo de parámetros que evalúan la calidad de la regla. La regla de asociación difusa consiste en un antecedente y un consecuente. Se permite que el antecedente tenga un número arbitrario de atributos mientras que el consecuente consiste en un solo atributo que no debe estar presente en el antecedente de la misma regla. Cada variable puede estar representada en la regla por una disyunción de términos lingüísticos (etiquetas) para facilitar una mayor generalización. Cada individuo tiene un total de ocho parámetros de calidad.

En cada iteración del proceso de aprendizaje de Fuzzy-CSar se recibe un nuevo ejemplo y el algoritmo lleva a cabo una serie de pasos para actualizar los parámetros de los individuos de la población y descubrir nuevas reglas relevantes. Para descubrir estas nuevas reglas prometedoras, se aplica un algoritmo genético estacionario basado en nichos [7]. Además, se aplican operadores de cruce, distintos tipos de mutación y *covering* con ciertas probabilidades. Podemos ver un esquema de la fase de aprendizaje de Fuzzy-CSar en el algoritmo 1. Complementariamente, explicamos brevemente algunos componentes de la fase de aprendizaje, una explicación más detallada se puede encontrar en [6].

### A. Parámetros de Calidad: Soporte y Confianza

En Fuzzy-CSar tenemos ocho parámetros de calidad para cada individuo de la población. Vamos a explicar cómo se calculan dos de ellos, los dos más utilizados y los más significativos para este trabajo: soporte y confianza (información sobre el cálculo de otros parámetros en [6]).

Si definimos formalmente el campo de minería de reglas de asociación como sigue [8]: Siendo  $I = i_1, i_2, \dots, i_l$  un conjunto de características binarias (ítems) de  $l$  elementos. Siendo  $Tr = tr_1, tr_2, \dots, tr_N$  un conjunto de  $N$  transacciones donde cada transacción  $tr_j$  contiene un vector binario que indica en cada posición si un ítem en particular está presente

### Algoritmo 1: Esquema de la fase de aprendizaje de Fuzzy-CSar [6]

```

proceso TrainFuzzy-CSar( ejemploEntrenamiento  $e_t$ ,
  Población [P] en el instante  $t$  )
Data:  $e_t$  tiene la forma  $\{x_i\}_{i=1}^l$ 
Result: Población [P] en el instante  $t + 1$ 
begin
   $e'_t \leftarrow$  granulación( $e_t$ );
  genera [M] a partir de [P] usando  $e'_t$ ;
  if  $|[M]| < \theta_{mna}$  then
    genera  $\theta_{mna} - |[M]|$  individuos que concuerdan usando  $e'_t$  y
    actualizando [P];
  end
  agrupa individuos en [M] por su antecedente formando distintos  $[A]_i$ ;
  selecciona [A] según probabilidad;
  subsume individuos en [A];
  actualiza individuos en [M]; // Por lo tanto, todos los
   $[A]_i$  se actualizan.
  if el tiempo medio en [A] desde la última vez de GA  $> \theta_{GA}$  then
    se lleva a cabo un evento genético en [A] considerando  $e'_t$  y
    actualizando [P];
  end
end

```

o no. Entonces un ítem  $X$  ( $X \subset I$ ) va a tener asociado un soporte que es una medida de su importancia en  $T$  y se calcula como  $supp(X) = |X(T)|/|T|$ , donde  $X(T)$  es el conjunto de variables en el antecedente de la regla. Si el soporte de un determinado *itemset* (conjunto de ítems) supera un umbral definido por el usuario (*minsupp*) este *itemset* se considera como un *conjunto frecuente de ítems*. Si  $X$  e  $Y$  son ambos conjuntos frecuentes de ítems y  $X \cap Y = \emptyset$ , podemos definir una regla de asociación como una implicación del tipo  $X \rightarrow Y$ . El soporte y la confianza de una regla de asociación son las medidas cualitativas tradicionalmente más usadas:

$$supp(X \rightarrow Y) = \frac{supp(X \cup Y)}{|T|}, \quad conf(X \rightarrow Y) = \frac{supp(X \cup Y)}{supp(X)}. \quad (1)$$

Donde el soporte indica la frecuencia con la que se cumplen los patrones y la confianza evalúa la fuerza de la implicación indicada en la regla de asociación.

Sea  $I = \{i_1, i_2, \dots, i_l\}$  un conjunto de  $l$  características,  $A \subset I$ ,  $C \subset I$  y  $A \cap C = \emptyset$ . Una regla de asociación difusa es una implicación de la forma  $X \rightarrow Y$  en la cual:

$$X = \bigwedge_{i_i \in A} \mu_{\tilde{A}}(i_i) \quad \text{e} \quad Y = \bigwedge_{i_j \in C} \mu_{\tilde{C}}(i_j), \quad (2)$$

donde  $\mu_{\tilde{C}}(i_j)$  es el grado de pertenencia de la variable en el consecuente y  $\mu_{\tilde{A}}(i_i)$  es el grado de pertenencia de las variables del antecedente. En esta situación, el soporte se extiende usando el producto T-norm y la confianza se extiende usando la *implicación de Dienes* [9]:

$$supp(X \rightarrow Y) = \frac{1}{|T|} \sum \mu_{\tilde{A}}(X) \cdot \mu_{\tilde{C}}(Y) \quad (3)$$

$$conf(X \rightarrow Y) = \frac{\sum (\mu_{\tilde{A}}(X) \cdot \max\{1 - \mu_{\tilde{A}}(X), \mu_{\tilde{C}}(Y)\})}{\sum \mu_{\tilde{A}}(X)}. \quad (4)$$

donde  $\mu_{\tilde{A}}(X)$  es el grado de pertenencia de la parte del antecedente de la regla y  $\mu_{\tilde{C}}(Y)$  es el grado de pertenencia de la parte del consecuente de la regla.

### B. Operador de Covering

Este operador genera nuevas reglas de asociación difusas cuando hay menos de  $\theta_{mna}$  (siendo  $\theta_{mna}$  un parámetro de configuración) individuos en el *match set*  $[M]$ , individuos de la población actual que concuerdan con el ejemplo recibido  $e$ .

El operador de covering construye un nuevo individuo que concuerda con  $e$  en el máximo grado posible: para cada variable de entrada de  $e$ ,  $e_i$ , el operador decide aleatoriamente si  $e_i$  va a formar parte del antecedente de la regla. Después, elige la variable que estará en el consecuente de entre aquellas que no han sido seleccionadas para formar parte del antecedente.

### C. Subsunción de Reglas

Para cada regla de  $[A]$  se comprueba su posible subsunción con cada una de las otras reglas del conjunto. Una regla  $r_i$  es una candidata para subsumir  $r_j$  si: (1)  $r_i$  es más general que  $r_j$ , y (2) ambas reglas tienen confianzas similares y  $r_i$  tiene la suficiente experiencia. Una regla  $r_i$  es considerada más general que  $r_j$  si todas las variables de  $r_i$  están también definidas en  $r_j$  y, para cada una de estas variables,  $r_i$  tiene, al menos, los mismos términos lingüísticos que  $r_j$ .

### D. Descubrimiento de Nuevas Reglas

Fuzzy-CSar usa un algoritmo genético incremental estacionario basado en nichos para descubrir nuevas reglas. Este algoritmo genético que se aplica al *association set* seleccionado, cuenta con tres tipos diferentes de mutación: (1) mutación del antecedente; (2) mutación del consecuente, y (3) mutación de términos lingüísticos.

En Fuzzy-CSar, como es común entre los miembros de la familia Michigan-style LCS [10], el coste del algoritmo se incrementa linealmente con el tamaño máximo de la población de reglas, el máximo número de variables por regla, y semi-logarítmicamente con el coste de ordenar el *match set*. Es importante resaltar que Fuzzy-CSar no depende directamente del número de transacciones, lo que lo hace muy adecuado para trabajar con grandes bases de datos. En el estudio aquí presentado, el algoritmo se aplica en un problema real (el cual se explica a continuación). La eficiencia es un requisito muy importante en minería de flujo de datos. En el problema aquí abordado, hemos estimado que el tiempo medio que Fuzzy-CSar tarda en procesar cada dato es de unos 15 milisegundos, siendo así factible procesar más de 60 muestras por segundo.

## III. ESTUDIO ‘FRIENDS AND FAMILY’

### A. Datos Originales

El estudio *Friends and Family*<sup>1</sup> es una investigación llevada a cabo por el MIT Media Lab, durante los años 2010 y 2011 [11]. Este estudio transforma una comunidad residencial cercana a una conocida universidad norteamericana en un *laboratorio viviente* durante 15 meses. Durante estos meses, los investigadores del Media Lab presentaron su sistema de registro de interacciones sociales y comportamiento basado en teléfonos móviles. Durante cerca de un año, toda actividad, comunicación y detalle social de las vidas de un gran número

<sup>1</sup><http://realitycommons.media.mit.edu/friendsdataset.html>

de miembros de la mencionada comunidad fue registrado mientras ellos realizaban sus tareas cotidianas con normalidad. Un total de 130 sujetos formaron parte del estudio. Durante el período del estudio, se recogió una gran cantidad de datos que resultó en un conjunto de datos muy completo y longitudinal, bautizado como *Friends and Family dataset*. Dicho conjunto de datos incluye una gran colección de señales basadas en la actividad del teléfono móvil incluyendo comunicación (llamadas y mensajes), aplicaciones instaladas, ejecución de aplicaciones, acelerómetro, dispositivos bluetooth próximos...

El estudio se dividió en dos fases. Una fase piloto de 6 meses de duración que comenzó en marzo de 2010, y una segunda fase iniciada en septiembre de 2010. Hasta 130 sujetos participaron en esta segunda fase.

Se proporcionaron *smartphones* a los participantes del estudio con la condición de que estos debían ser sus teléfonos principales durante su participación en el estudio. Estos dispositivos harían el papel de sensores sociales *in-situ* para registrar las características de la actividad de los sujetos.

Parte de la colección de datos obtenida del ‘‘Estudio Friends and Family’’ fue publicada y ha servido como punto de partida para nuestro estudio. El tamaño de esta parte publicada de la colección supera los 7GB. Además, esta gran cantidad de datos está distribuida en distintos archivos cuyo origen, formato y estructura varían.

Los datos recogidos de los teléfonos móviles son el núcleo principal de la colección de datos construida a partir del estudio. La tabla I enumera algunos tipos de información incluidos en esta colección y utilizados en nuestro estudio, junto con sus frecuencias de muestreo originales.

Tabla I: Principales tipos de información incluidos en los datos originales y usados en nuestro estudio

Información	Frecuencia muestreo
Dispositivos bluetooth próximos	cada 5 minutos
Registro de llamadas	cuando una llamada es enviada/recibida
Registro de SMS	cuando un SMS es enviado/recibido
Aplicaciones en el dispositivo	cada 10 minutos
Aplicaciones en ejecución	cada 30 segundos

Dado el origen y las peculiaridades de la información recogida, el estudio se llevó a cabo bajo estrictos protocolos que aseguran la privacidad de todos los participantes.

### B. Preparación del Flujo de Datos

La estructura original de los datos no era la más adecuada para el proceso de extracción de conocimiento ni para obtener resultados de calidad. Por lo tanto, los datos tuvieron que ser tratados antes de aplicar el algoritmo. Los datos se encontraban distribuidos en diferentes archivos con diferente formato, estructura y frecuencia de muestreo dependiendo del tipo de información y del método de recolección utilizado. Cada tipo de información había sido registrado con sus propias peculiaridades, los datos de todos los participantes estaban mezclados y no todos los sujetos estuvieron implicados al mismo nivel en el estudio. Fue necesario aplicar un proceso de preparación sobre los datos en bruto para obtener un conjunto de datos completo, unificado y específico para cada sujeto.



En primer lugar, se realizó un estudio exploratorio de los datos para conocer y comprender mejor el problema. No toda la información original resulta útil para nuestros objetivos. Es necesario decidir qué información es relevante y cuál no.

Un algoritmo evolutivo completamente en línea presenta algunas peculiaridades dado que cada dato va a ser procesado una sola vez y el algoritmo no va a tratar con el conjunto de datos completo en ningún momento. Esto puede hacer que cierta información aparezca solo por un momento para acabar desapareciendo para el algoritmo a pesar de que puedan proporcionar información relevante. Tratando de minimizar este riesgo, se generaron variables del tipo “cuántas llamadas se han registrado en los últimos X minutos”. Finalmente, se eligió una frecuencia de muestreo unificada de un minuto para los conjuntos de datos finales tratando de no perder demasiado detalle pero, al mismo tiempo, intentando evitar que el nivel de granularidad de los datos se vuelva innecesariamente bajo.

Para clarificar y resumir, describimos cada paso de la preparación de datos.

- 1) **Filtrado de datos por fecha:** se seleccionan los datos a partir del 01/10/2010, excluyendo los de la fase piloto.
- 2) **Agrupamiento de datos por participante:** se agrupa todos los datos de cada participante.
- 3) **Duplicados y orden cronológico:** eliminamos registros duplicados y ordenamos cronológicamente.
- 4) **Integración de datos:** los datos libres de duplicados y ordenados cronológicamente recogidos durante la segunda fase del estudio para cada participante se integran en conjuntos de datos individuales.

La figura 1 representa la evolución en el tiempo para los principales atributos después del proceso de preparación de los datos. Los datos presentados en dicha figura corresponden a un sujeto elegido como ejemplo para el análisis de resultados (Sección IV). El gráfico de la figura 1 tiene una resolución diaria, por lo que debemos tener en cuenta que los valores mostrados para las variables acumulativas (llamadas y contadores de mensajes) en los gráficos para un día dado son diez veces el número real de llamadas/mensajes. Esta figura nos ayuda a entender lo difícil que sería extraer información útil y descubrir asociaciones interesantes sin la asistencia proporcionada por el algoritmo de minería de flujo de datos.

#### IV. EXPERIMENTACIÓN Y RESULTADOS

##### A. Diseño de Experimentos

Los atributos de entrada utilizados en la experimentación realizada para obtener los resultados presentados en este trabajo son los siguientes: día de la semana; minuto del día [0, 1439]; porcentaje de batería; tres contadores de SMS en los últimos 10 minutos (entrantes, salientes y global); cuatro contadores de llamadas durante los últimos 10 minutos (entrantes, salientes, perdidas y global); tres variables referentes a acelerómetro; alguna aplicación desinstalada y alguna aplicación en ejecución.

La tabla II muestra los valores asignados a los principales parámetros de configuración de Fuzzy-CSar para los experimentos (cuyos resultados se discuten a continuación).

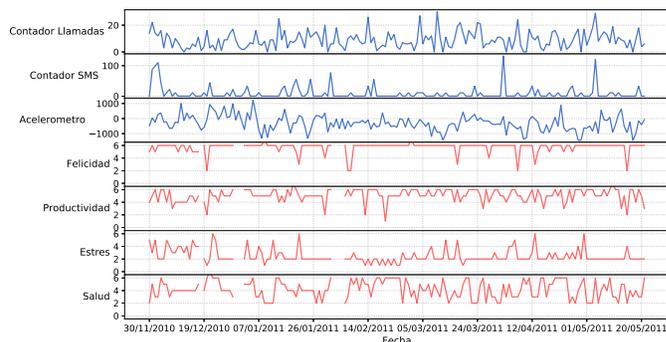


Figura 1: Representación gráfica de la evolución de algunos atributos que forman el conjunto de datos de uno de los participantes (Identificador del participante: sp10-01-24)

Tabla II: Principales parámetros de configuración de Fuzzy-CSar junto con los valores asignados en los experimentos

Parámetro	Valor
Tamaño máximo población	10.000
Comprobar subsunción	Sí
Tipo de <i>association sets</i>	Antecedente
Número máximo de conjuntos difusos	Dependiente del rango de la variable
Forzar etiquetas adyacentes	Sí
Número máximo de término lingüísticos	60% de los conjuntos difusos
Mutación	Sí
Comprobar subsunción en el GA	Sí

##### B. Análisis de Resultados

Como se ha explicado, Fuzzy-CSar mantiene continuamente una población de reglas. Es complicado encontrar una manera de trazar la evolución completa de toda esta población. Para poder representar y analizar esta evolución, nos centramos en ciertas reglas completas, consecuentes y antecedentes.

La figura 2 puede ayudar a entender mejor la descripción de algunas reglas de asociación que se muestran en esta sección. En ella es posible observar un esquema de la nomenclatura empleada para referirnos a los conjuntos difusos usados por Fuzzy-CSar para atributos numéricos.

Según estas nomenclaturas, la tabla III muestra tres reglas obtenidas por Fuzzy-CSar. Estos ejemplos ayudan a entender y visualizar mejor la estructura de las reglas de asociación obtenidas por Fuzzy-CSar. En la figura 3 podemos ver la evolución del número de copias almacenadas en la población (numerosidad), lo que representa la importancia relativa de la regla en cada momento, para cada una de las reglas representadas en la tabla III. Podemos observar cómo esta evolución es completamente diferente para cada regla.  $R_1$  (rojo) aparece en un cierto momento, luego la numerosidad de la regla aumenta, para posteriormente disminuir hasta que la regla desaparece. Pero después de eso, la regla aparece de nuevo y repite el mismo proceso. Sin embargo, la regla  $R_2$  (azul) aparece cerca del mes de abril para continuar aumentando su numerosidad hasta el final del experimento. Finalmente, la regla  $R_3$  (verde) existe en la población desde el principio y su numerosidad es siempre creciente. Si analizamos la asociación representada por  $R_3$  esta evolución parece muy lógica ya que normalmente

la gente duerme por la noche y no hace ninguna llamada por lo que esta condición es casi siempre cierta.

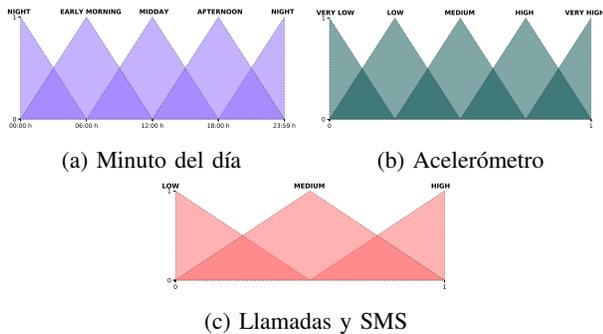


Figura 2: Nomenclatura empleada para los conjuntos difusos en las variables referentes a: (a) minutos del día, (b) acelerómetro, y (c) contadores de llamadas y mensajes

Tabla III: Ejemplos de reglas generadas por Fuzzy-CSar durante los experimentos (figura 3)

ID	Rule	Soporte*	Confianza*
$R_1$	Si hora es MIDDAY o AFTERNOON entonces acelerómetro es MEDIUM, HIGH, VERY HIGH	0.124	0.802
$R_2$	Si número de SMS salientes es LOW entonces acelerómetro es HIGH, VERY HIGH	0.606	0.709
$R_3$	Si hora es NIGHT o EARLY MORNING y número de SMS entrantes es LOW entonces número de llamadas salientes es LOW	0.496	0.997

\* El soporte y confianza se refieren al momento con máximo número de copias

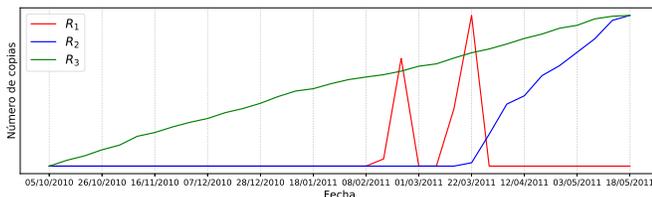


Figura 3: Evolución del número de copias en la población (numerosidad) de:  $R_1$  (máximo 21 copias),  $R_2$  (máximo 90 copias) y  $R_3$  (máximo 537 copias) (tabla III)

Generalizando un poco nuestro análisis podemos centrarnos en un consecuente determinado en lugar de en una regla determinada. Siguiendo esta idea presentamos una serie de gráficos en los que analizamos la evolución en numerosidad de un conjunto específico de reglas que contienen la misma variable en su consecuente o incluso la misma etiqueta. Como prueba de concepto, a continuación se analiza la evolución de la cantidad de actividad física practicada por el participante.

La variable *AccelAccum*, incluida en el conjunto de datos usado, presenta valores relacionados con la información de acelerometría recogida de los *smartphones* de los participantes. Los investigadores del MIT relacionan dicha información de acelerometría con la actividad física, como también lo hacen otros investigadores [12]. Siguiendo esta interpretación,

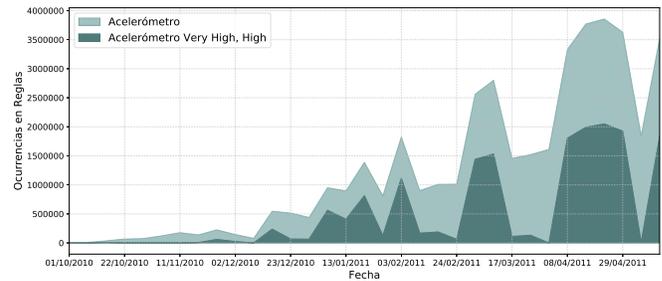


Figura 4: Comparativa entre la evolución en el nº total de reglas con *AccelAccum* en el consecuente y el número de ellas con la etiqueta VERY HIGH, HIGH ( $supp \geq 0.1$  y  $conf \geq 0.7$ ). Datos del participante *sp10-01-24*

entendemos que un mayor número de reglas cuyos consecuentes apuntan a valores *HIGH*, *VERY-HIGH* de la variable *AccelAccum* puede ser interpretado como un indicador de un aumento de la actividad física practicada por el sujeto. La figura 4 representa la evolución en el número de reglas, que superan los umbrales de soporte y confianza, cuyos consecuentes contienen la variable *AccelAccum* con cualquier etiqueta (área color claro) y las reglas cuyos consecuentes contienen valores altos de la variable *AccelAccum* (área color oscuro). Teniendo esto en cuenta, el gráfico representado en la figura 4 muestra cómo el participante *sp10-01-24* aumenta la cantidad de actividad física durante ciertos períodos de tiempo.

La figura 5 nos ayuda a entender la distribución de los valores de *AccelAccum* durante un cierto periodo de tiempo. Como se observa, no hay concentraciones especiales de valores altos o muy altos. El algoritmo comienza a encontrar relaciones que explican los altos valores de *AccelAccum* y, como consecuencia, aumenta el número de reglas con este consecuente específico y suficiente confianza.

Dado que se ha utilizado un algoritmo de reglas de asociación, y no uno de patrones frecuentes, podemos utilizar las relaciones establecidas por las reglas de asociación entre antecedentes y consecuentes como parte de nuestro análisis.

Así, profundizamos en los resultados analizando la composición del antecedente de las reglas con altos valores de *AccelAccum* en el consecuente. La figura 6 representa la evolución de estas reglas de calidad distinguiendo entre variables en el antecedente. En esta figura se muestra cómo la mayoría de los antecedentes se relacionan con la no utilización de varias funciones del teléfono móvil, por ejemplo, llamadas, mensajes, aplicaciones.... Los antecedentes agrupados bajo la etiqueta “Otro” se relacionan principalmente con la hora y el día de la semana. Este hecho refuerza la idea de que los valores altos del acelerómetro están relacionados con la actividad física y no con otros tipos de uso del *smartphone*.

## V. CONCLUSIONES

En este trabajo hemos mostrado una aplicación real de un algoritmo evolutivo (Fuzzy-CSar) para minería de reglas de asociación en flujo de datos, cuyo objetivo es descubrir de forma on-line y en tiempo real las relaciones entre los atributos

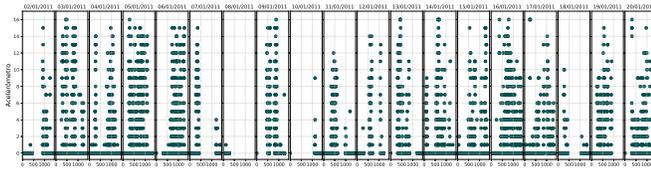


Figura 5: Distribución de los valores de la variable *AccelAccum* a lo largo de los minutos de cada día del 2 al 21 de enero de 2011. Datos del participante *sp10-01-24*

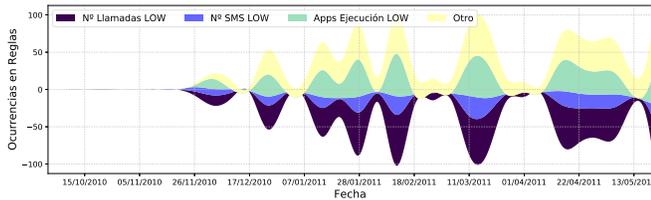


Figura 6: Comparación entre la evolución del nº total de reglas ( $supp \geq 0.1$  y  $conf \geq 0.7$ ) cuyo consecuente contiene *AccelAccum* con etiqueta VERY HIGH, HIGH y el nº de ellas con antecedentes referidos a la inactividad del teléfono. Datos del participante *sp10-01-24*

de un flujo de datos. Esta aplicación simula un sistema de monitorización en el que los datos de entrada consisten en muestras reales basadas en información sobre llamadas, SMS, acelerómetros, aplicaciones, etc. recogida desde *smartphones*. Estos datos constituyen un claro ejemplo de problema real en el que la información se genera como un flujo continuo e infinito y puede ser explotada de forma muy productiva sin necesidad de ser almacenada en grandes conjuntos de datos que requieran altas capacidades de procesamiento.

En este caso, el algoritmo evolutivo descubre reglas en tiempo real para explicar lo que está sucediendo en todo momento. Los resultados muestran la evolución que está experimentando la población de reglas de asociación a medida que aumenta la cantidad de datos procesada. Estos son solo algunos ejemplos que muestran cómo el algoritmo Fuzzy-CSar y las reglas de asociación descubiertas por él, hacen posible descubrir nuevas relaciones que no habrían sido descubiertas directamente a partir de datos en bruto. Además, esto se consigue de una manera muy eficiente, ya que Fuzzy-CSar tarda solo 15 ms en procesar cada dato, es decir, en el caso específico de datos con esta estructura es capaz de lidiar con una frecuencia de entrada de unos 67 Hz. En un entorno donde los datos llegan en tiempo real en forma de flujo infinito, como en este trabajo, es posible generar y actualizar un modelo en tiempo real, permitiendo un proceso de monitoreo que puede ayudar en un sistema de toma de decisiones. Otro posible caso de uso podría ser integrar este algoritmo en una aplicación móvil que utilice directamente el conocimiento descubierto por el algoritmo para tomar decisiones (por ejemplo, recomendaciones musicales o sugerencia de aplicaciones) basadas en reglas específicas. Dado que el algoritmo no asume ninguna estructura de problema a priori, es capaz de adaptarse a las

características de los datos de cada sujeto. Cabe destacar la importancia de utilizar un algoritmo con capacidad para adaptarse a los cambios conceptuales, ya que a menudo estos cambios proporcionan la información más relevante.

En conclusión, en este trabajo se muestra el potencial de la minería de reglas de asociación en flujo de datos para la monitorización de problemas reales. El trabajo realizado y los resultados obtenidos revelaron que el desarrollo de un sistema capaz de monitorizar el uso que una persona está haciendo de su teléfono a través de un algoritmo de minería de asociaciones en flujos de datos (utilizando técnicas on-line e incrementales), descubriendo información útil, es una opción factible. En este momento, se están considerando varias líneas para continuar con este trabajo, entre las que se incluyen las siguientes: (1) continuar con las mejoras de Fuzzy-CSar y pulir las adaptaciones del algoritmo a los datos de actividad de teléfonos móviles, (2) estudiar más profundamente los resultados obtenidos en este conjunto de datos, (3) aprovechar la buena eficiencia de Fuzzy-CSar para la integración en dispositivos móviles, y (4) desarrollar aplicaciones para obtener más datos de este tipo utilizando luego la información relevante descubierta a través de las asociaciones aprendidas.

## REFERENCES

- [1] J. Gama, *Knowledge discovery from data streams*. Chapman & Hall/CRC, 2010.
- [2] M. Sayed-Mouchaweh and E. Lughofer, *Learning in non-stationary environments : methods and applications*. Springer, 2012.
- [3] A. Orriols-Puig and J. Casillas, "Fuzzy knowledge representation study for incremental learning in data streams and classification problems," *Soft Computing*, vol. 15, no. 12, pp. 2389–2414, dec 2011.
- [4] S. Guha, A. Meyerson, N. Mishra, R. Motwani, and L. O'Callaghan, "Clustering data streams: theory and practice," *IEEE Transactions on Knowledge and Data Engineering*, vol. 15, no. 3, pp. 515–528, may 2003.
- [5] G. Corral, A. Garcia-Piquer, A. Orriols-Puig, A. Fornells, and E. Golo-bardes, "Analysis of vulnerability assessment results based on CAOS," *Applied Soft Computing*, vol. 11, no. 7, pp. 4321–4331, oct 2011.
- [6] A. Sancho-Asensio, A. Orriols-Puig, and J. Casillas, "Evolving association streams," *Information Sciences*, vol. 334–335, pp. 250–272, mar 2016.
- [7] S. W. Wilson, "Classifier Fitness Based on Accuracy," *Evolutionary Computation*, vol. 3, no. 2, pp. 149–175, jun 1995.
- [8] R. Agrawal, T. Imieliński, A. Swami, R. Agrawal, T. Imieliński, and A. Swami, "Mining association rules between sets of items in large databases," in *Proceedings of the 1993 ACM SIGMOD international conference on Management of data - SIGMOD '93*, vol. 22, no. 2. New York, New York, USA: ACM Press, 1993, pp. 207–216.
- [9] D. Dubois, E. Hüllermeier, and H. Prade, "A systematic approach to the assessment of fuzzy association rules," *Data Mining and Knowledge Discovery*, vol. 13, no. 2, pp. 167–192, sep 2006.
- [10] A. Orriols-Puig, J. Casillas, and F. J. Martínez-López, "Unsupervised Learning of Fuzzy Association Rules for Consumer Behavior Modeling," *Mathware & Soft Computing*, vol. 16, pp. 29–43, 2009.
- [11] N. Aharony, W. Pan, C. Ip, I. Khayal, and A. Pentland, "Social fMRI: Investigating and shaping social mechanisms in the real world," *Pervasive and Mobile Computing*, vol. 7, no. 6, pp. 643–659, dec 2011.
- [12] J. Bort-Roig, N. D. Gilson, A. Puig-Ribera, R. S. Contreras, and S. G. Trost, "Measuring and Influencing Physical Activity with Smartphone Technology: A Systematic Review," *Sports Medicine*, vol. 44, no. 5, pp. 671–686, may 2014.

# Un Sistema de Recomendación de Asignaturas Multi-Criterio con Optimización Genética

Aurora Esteban, Amelia Zafra, Cristóbal Romero  
*Departamento de Informática y Análisis Numérico*  
*Universidad de Córdoba*  
Córdoba, España

**Resumen**—Este artículo propone un Sistema de recomendación (SR) híbrido multi-criterio para resolver el problema de recomendación de asignaturas en los estudios universitarios. Por un lado, utiliza Filtrado Colaborativo (FC) con la información del estudiante y por otro lado, Filtrado Basado en Contenido (FBC) con la información de las asignaturas. Para determinar los factores que resultan más relevantes en la recomendación, así como para optimizar la configuración del SR híbrido en lo referente a las medidas de distancia a considerar y el tamaño del vecindario, se ha diseñado un Algoritmo Genético (AG) que optimiza de forma automática el ajuste de todos los parámetros. Un estudio experimental con 2500 valoraciones reales de los estudiantes del Grado en Ingeniería Informática de la Universidad de Córdoba, demuestra los excelentes resultados obtenidos por el SR propuesto y la importancia de utilizar un modelo híbrido donde los diferentes criterios utilizados sean ponderados de acuerdo a su relevancia.

**Index Terms**—Sistema de recomendación, Filtrado colaborativo, Filtrado basado en contenido, Algoritmo genético

## I. INTRODUCCIÓN

En la era de la información que recientemente se vive, los Sistemas de Recomendación (SR) se han consolidado en diversos campos, entre los que se encuentran los entornos educativos. Específicamente, la recomendación de asignaturas o cursos se ha afianzado como una interesante y creciente línea de investigación dentro de la minería de datos aplicada a la educación [1]. En el caso concreto de la recomendación de asignaturas en los estudios universitarios, su importancia viene dada por el hecho de que los estudios universitarios tienen un número variable de asignaturas optativas entre las que los estudiantes deben elegir para completar los créditos de la titulación que están cursando. Normalmente, los estudiantes no cuentan con información suficiente para hacer esta elección, y recurren a compañeros que la hayan cursado para conocer su opinión. En este contexto, los SR se presentan como una herramienta esencial, capaz de ofrecerles asignaturas relevantes en base a sus preferencias individuales, sus intereses, sus necesidades o su rendimiento [2].

Aunque existen algunos estudios que trabajan con enfoques de SR híbridos [3], [4] o con múltiples criterios [5], [6], no incluyen todos los criterios aquí considerados, ni se

centran en estudiar la influencia que los diferentes factores tienen en el proceso de recomendación.

En este trabajo se presenta un SR híbrido multi-criterio, que combina una técnica de Filtrado Colaborativo (FC) utilizando información del estudiante (considerando como criterios, sus valoraciones, sus calificaciones y la especialidad cursada dentro de la carrera), con una técnica de Filtrado basado en Contenido (FBC) utilizando información de las asignaturas (considerando como criterios, sus competencias, profesores, contenidos teóricos o prácticos y área de conocimiento). Para determinar la importancia de cada criterio se propone un Algoritmo Genético (AG) que optimice los pesos asignados a cada uno de estos criterios en el SR. Así mismo, otros parámetros del SR como las métricas de similitud utilizadas, o el número de vecinos también serán optimizadas simultáneamente. En la metodología propuesta, el SR es configurado con los parámetros optimizados por el AG, para finalmente, realizar las recomendaciones finales a los estudiantes.

Con el fin de garantizar una evaluación rigurosa del SR, se va a utilizar un conjunto de datos proveniente del Grado en Ingeniería Informática de la Universidad de Córdoba (España), que incluye valoraciones y calificaciones de estudiantes reales. Así mismo, en el proceso de evaluación se utilizará validación cruzada manteniendo el equilibrio entre las particiones de datos.

El resto del trabajo se organiza como sigue. En la sección II se hace un repaso de los trabajos previos. En la sección III se especifica la metodología propuesta, describiendo tanto la información, como el SR híbrido diseñado. En la sección IV se explica el AG utilizado para la optimización. En la sección V se describe el estudio experimental realizado, tanto el estudio de la relevancia de los criterios, como la comparativa con otros modelos. Finalmente, la sección VI presenta las conclusiones obtenidas y el trabajo futuro.

## II. TRABAJOS RELACIONADOS

En los últimos años los SR multi-criterio han sido ampliamente aplicados a la recomendación de asignaturas o cursos. S. Spiegel [7] explora una de las primeras aplicaciones de factorización de matriz multi-criterio para la predicción de valoraciones de asignaturas. Más adelante, Vialardi et al. [5] propusieron técnicas multi-criterio para la predicción de calificaciones de estudiantes abordadas



como un problema de clasificación, y Parameswaran et al. [8] exploraron la aplicación de restricciones a la recomendación multi-criterio. Así mismo, se ha explorado la aplicación de otras técnicas, como propuestas basadas en ontologías [9], [10], redes neuronales [11], y algoritmos bio-inspirados como colonias de hormigas [12] o sistemas inmunes artificiales [3]. La mayoría de estas propuestas sólo están basados en las valoraciones de los estudiantes. Desde otra perspectiva, la importancia del momento en el que se cursan las asignaturas ha sido estudiada usando Cadenas de Markov en base a las calificaciones [13], así como aplicando multi-criterio [14]. Recientemente, se ha estudiado la relevancia de las competencias que las asignaturas ofrecen [6] o la aplicación de análisis semántico [15].

Se puede resumir que la mayoría de los enfoques se centran principalmente en el rendimiento de los estudiantes, y no usan criterios adicionales. Además, los sistemas que utilizan más criterios, no hacen ningún estudio para determinar la influencia de cada uno de ellos en la calidad de las recomendaciones, mostrando así los beneficios que aporta nuestra propuesta.

### III. PROPUESTA DE SISTEMA DE RECOMENDACIÓN HÍBRIDO

En esta sección se describe la metodología propuesta, especificando desde la recolección y preparación de los datos, hasta el desarrollo de la propuesta planteada.

#### A. Descripción y preparación de los datos

Este trabajo se ha desarrollado utilizando los datos recogidos del Grado en Ingeniería Informática de la Universidad de Córdoba (España). Estos datos son relativos tanto a los estudiantes, como a las asignaturas.

1) *Información de estudiante*: la información de los estudiantes (figura 1) se ha obtenido por medio de encuestas realizadas durante tres cursos académicos (de 2016 a 2018) a los alumnos de los últimos cursos, recogiendo un total de 2500 valoraciones de 63 asignaturas incluidas en el plan de estudios. La información que se ha considerado es:

- Una valoración de la satisfacción general del estudiante en cada asignatura, representada como un valor numérico entero entre 1 y 5. El valor máximo correspondería a un 5, y el mínimo a un 1.
- La calificación obtenida por el estudiante para cada asignatura, representada con un valor numérico real, en el rango  $[0, 10]$ .
- La especialidad seleccionada por el estudiante. Concretamente, el grado en Ingeniería Informática que se estudia, ofrece tres especialidades: computación, computadores e ingeniería del software, representados con un identificador numérico de 1 a 3.

2) *Información de la asignatura*: la información de las 63 asignaturas consideradas en el plan de estudios (figura

	A1	A2	A3	...	A62	A63	A1	A2	A3	...	A62	A63	
$E_i$	5	2		...	4		8.5	6.3		...	9		2
	Valoraciones						Calificaciones						Espec.

Figura 1. Información del estudiante

2), se ha obtenido de la página oficial del grado dentro de la Universidad<sup>1</sup>. La información que se ha considerado es:

- Los profesores que imparten docencia en cada asignatura, representados con un vector binario, indicando con el valor 1 si el profesor ha impartido la asignatura y con el valor 0 si no la ha impartido.
- Las competencias que se deben adquirir al realizar la asignatura, representadas con un vector binario, indicando con el valor 1 que la asignatura proporciona la competencia, y con el valor 0 que no la proporciona.
- El área de conocimiento al que la asignatura pertenece, representada con un identificador numérico de 1 a 8, ya que en el grado estudiado se contemplan ocho áreas de conocimiento diferentes.
- Los contenidos teóricos y prácticos de la asignatura, representados con un vector de frecuencias de las palabras claves. Las palabras claves son obtenidas a partir del procesamiento automático de textos aplicado a la guía docente de cada asignatura.

	P1	P2	P3	...	P57	P58	Cm1	Cm2	Cm3	...	Cm52	Cm53		
$A_i$	1	0	1	...	0	1	0	1	1	...	0	1	6	
	Profesores						Competencias						Área conóc.	Contenidos

Figura 2. Información de la asignatura

#### B. Sistema de Recomendación

El SR híbrido multi-criterio propuesto en este trabajo combina las valoraciones obtenidas por un sistema basado en FC (especificado en la sección III-B1 y las obtenidas por un sistema de FBC (especificado en la sección III-B2). De este modo, la estimación de preferencia  $p$  de un estudiante  $i$  sobre una asignatura  $j$ , se calcula como la combinación lineal de las preferencias dadas por el FC ( $FC_{i,j}$ ) y el FBC ( $FBC_{i,j}$ ):

$$p_{i,j} = \alpha \cdot FC_{i,j} + \beta \cdot FBC_{i,j} \quad (1)$$

Con  $\alpha + \beta = 1$

Tanto en el sistema FC, como en el FBC se representan las valoraciones estimadas de cada asignatura en un rango de  $[1, 5]$ , por lo que la estimación final también estará en dicho rango.

Se puede apreciar en la ecuación 1, que los parámetros que determinan la relevancia que se le da a la valoración obtenida por cada uno de los sistemas considerados son los pesos  $\alpha$  y  $\beta$ , que deben ser configurados.

<sup>1</sup><http://www.uco.es/eps/node/619>

En los siguientes apartados se especifican las características del sistema de FC y del sistema de FBC que se han diseñado.

1) *Filtrado Colaborativo utilizando la información del estudiante*: en el sistema de FC desarrollado, la valoración estimada de una asignatura para un estudiante se obtiene a partir de las valoraciones que ésta ha recibido por parte del resto de estudiantes con un perfil similar.

El aspecto multi-criterio es introducido en el cálculo de la similitud entre estudiantes: para cada par de estudiantes  $i$  y  $j$ , la similitud,  $s$ , agrega tres medidas de similitud que están en el rango  $[0, 1]$ : por un lado, calcula la similitud según sus valoraciones  $V_{i,j}$  y sus calificaciones  $C_{i,j}$ , por otro lado, comprueba si la especialidad que están cursando ambos estudiantes coincide ( $E_{i,j}$ ). Finalmente, los tres criterios se agregan en una combinación lineal:

$$s_{i,j} = \alpha \cdot V_{i,j} + \beta \cdot C_{i,j} + \gamma \cdot E_{i,j} \quad (2)$$

$$\text{Con } \alpha + \beta + \gamma = 1$$

Por tanto, será necesario configurar las métricas utilizadas para valoraciones y calificaciones, el vecindario, y los pesos  $\alpha$ ,  $\beta$  y  $\gamma$  de los criterios considerados.

2) *Filtrado basado en Contenido utilizando la información de la asignatura*: en el sistema de FBC desarrollado, la valoración estimada de una asignatura para un estudiante se obtiene a partir de la valoración que él mismo ha hecho de las asignaturas más similares a ésta.

El aspecto multi-criterio es introducido en el cálculo de la similitud entre asignaturas: para cada par de asignaturas  $i$  y  $j$ , la similitud ( $s$ ) es una combinación de cuatro medidas que están en el rango  $[0, 1]$ : por un lado se calcula cuántos profesores y competencias tienen en común,  $P_{i,j}$  y  $Cm_{i,j}$ , respectivamente. Por otro lado, se comprueba si el área de conocimiento coincide  $A_{i,j}$ , y finalmente, se obtiene la similitud según los contenidos aplicando minería de textos  $Cn_{i,j}$ , siguiendo el procedimiento especificado más adelante. Finalmente, se calcula la similitud final mediante una combinación lineal:

$$s_{i,j} = \alpha \cdot P_{i,j} + \beta \cdot Cm_{i,j} + \gamma \cdot A_{i,j} + \delta \cdot Cn_{i,j} \quad (3)$$

$$\text{Con } \alpha + \beta + \gamma + \delta = 1$$

Por tanto, para aplicar FBC será necesario determinar las métricas usadas para  $P_{i,j}$  y  $Cm_{i,j}$  y la relevancia de cada criterio por medio de los pesos  $\alpha$ ,  $\beta$ ,  $\gamma$  y  $\delta$ .

La similitud según los contenidos de la asignatura es obtenida a partir de la información descrita en su guía docente mediante minería de textos. El proceso compara los contenidos de dos asignaturas, para finalmente dar un valor de similitud entre 0 y 1:

1) Indexación del apartado *Contenidos* de las guías docentes de las asignaturas: este proceso se lleva a cabo con un analizador sintáctico y con un conjunto de *stop-words* específicas al dominio. Como resultado

se obtiene para cada documento un conjunto de *tokens* junto a sus frecuencias de aparición.

- 2) Para cada par de asignaturas  $i$  y  $j$ , se crea un conjunto  $B$  que es la unión de sus *tokens*, y para cada asignatura, se crea un vector  $\vec{i}$  y  $\vec{j}$  que tendrá una posición por cada *token* en  $B$  indicando la frecuencia de aparición del mismo. Finalmente, se aplica la norma  $l_1$  sobre cada vector para obtener las frecuencias relativas.
- 3) Finalmente, a los 2 vectores de frecuencias se les aplica la similitud del coseno, obteniendo el valor  $Cn_{i,j}$  que se integra en la ecuación parametrizable descrita en 3:

$$\cos(\theta) = \frac{\vec{i} \cdot \vec{j}}{\|\vec{i}\| \cdot \|\vec{j}\|} = \frac{\sum_{k=1}^n i_k j_k}{\sqrt{\sum_{k=1}^n i_k^2} \sqrt{\sum_{k=1}^n j_k^2}} \quad (4)$$

#### IV. OPTIMIZACIÓN DEL SISTEMA DE RECOMENDACIÓN MEDIANTE ALGORITMOS GENÉTICOS

El SR que aquí se presenta, descrito en la sección III-B, cuenta con múltiples criterios que deben ser ponderados con un peso que indique la relevancia que va a tener cada uno de ellos, así como con la configuración de diferentes métricas de similitud para cada uno de ellos, y del tamaño del vecindario a utilizar. Por ello, se ha decidido diseñar un AG que automáticamente descubra una configuración óptima de todos los parámetros del SR y permita obtener unas recomendaciones lo más satisfactorias posibles para los estudiantes.

A continuación, se especifica las características del AG que se ha diseñado y que sigue un esquema generacional con elitismo.

##### A. Representación de los individuos

Los individuos de la población se codifican mediante un cromosoma entero compuesto de 14 genes:

- Los dos primeros genes son los pesos que se van a utilizar para combinar las recomendaciones obtenidas por el FC utilizando la información del estudiante y por el FBC utilizando la información de la asignatura. Concretamente, serían los valores  $\alpha$  y  $\beta$  definidos en la ecuación 1.
- Los tres siguientes genes se corresponden con los pesos que se asignan a los tres criterios que se han considerado en el FC utilizando la información del estudiante. Concretamente, serían los valores de  $\alpha$ ,  $\beta$  y  $\gamma$  definidos en la ecuación 2.
- Los cuatro siguientes genes codifican los pesos que son asignados a los cuatro criterios utilizados en el FBC que emplea la información de la asignatura. Concretamente, serían los valores de  $\alpha$ ,  $\beta$ ,  $\gamma$  y  $\delta$  definidos en la ecuación 3.
- El siguiente gen es el número de vecinos tenidos en cuenta para realizar las estimaciones.
- Los dos siguientes genes son las métricas utilizadas para calcular la similitud según las valoraciones y las



calificaciones respectivamente. Sus valores son tratados como categóricos, y se corresponderán con las métricas contempladas para obtener estas similitudes.

- Los dos últimos genes se corresponden con las métricas utilizadas para calcular la similitud según los profesores y las competencias. Al igual que el grupo anterior, tomarán valores categóricos que se corresponderán con las métricas contempladas para obtener estas similitudes.

### B. Operadores genéticos

1) *El operador de cruce*: es un cruce uniforme que selecciona gen a gen de qué padre toma la información que pasará al hijo. La particularidad de este operador es que el conjunto de genes: (1,2), (3,4,5) y (6,7,8,9) son tratados en bloque, de forma que cada bloque completo es seleccionado del mismo padre para que lo herede uno de los hijos.

2) *El operador de mutación*: es una mutación uniforme, donde para cada individuo que va a ser mutado, se selecciona cada gen con una cierta probabilidad y se cambia su valor por otro valor aleatorio dentro del rango de valores definidos para ese gen.

3) *Optimizador local*: este operador, similar a los empleados en los algoritmos meméticos [16], consiste en realizar una pequeña modificación en los genes que representan las medidas de similitud y el número de vecinos de un mismo individuo. Si el cambio realizado hace que el individuo tenga una mejor función de aptitud, se continúa realizando cambios, hasta un máximo de cinco variaciones. Finalmente, si el individuo obtenido mejora al individuo inicial, lo sustituye en la nueva población, en caso contrario, el nuevo individuo obtenido será eliminado. Debido, al coste computacional de este operador, solamente es aplicado al mejor individuo de la población.

### C. La función de aptitud

La función de aptitud o *fitness* que se emplea es la raíz del error cuadrático medio (RMSE) entre las valoraciones reales y las estimadas. Para optimizar los tiempos de cómputo, el fitness se obtendrá utilizando el 80% de los datos como valores conocidos y el restante 20% como datos a estimar para obtener el valor de RMSE.

## V. ESTUDIO EXPERIMENTAL

Esta sección describe la experimentación realizada. El SR se ha desarrollado dentro del *framework* Apache Mahout<sup>2</sup> y el AG utilizando la *librería* JCLEC<sup>3</sup>. La máquina sobre la que se han ejecutado las pruebas es un ordenador personal con SO Ubuntu 16.04 64-bits, un procesador Intel Core i5-3317U y 12 GB de RAM.

<sup>2</sup><https://mahout.apache.org/>

<sup>3</sup><http://jclec.sourceforge.net/>

### A. Configuración del Algoritmo Genético

Los principales parámetros utilizados en el AG, tras un estudio de diferentes configuraciones, son: tamaño de la población: 200, número de generaciones: 100, y probabilidad de mutación y cruce: 0.5 y 0.9 respectivamente.

Con respecto al rango de valores de cada gen: los 9 primeros genes que representan los pesos de cada criterio considerado, se han definido en el rango [0, 10]. Este rango podría variarse, ya que estos valores son normalizados antes de ser utilizados en las ecuaciones 1, 2 y 3. El gen 10, que representa el número de vecinos, se ha definido en el rango [1, 50]. Los genes 11 y 12 que representan las medidas de similitud de las valoraciones y las calificaciones, se definen en el rango [0, 4] representando las 5 métricas consideradas, la distancia euclidiana, la distancia Manhattan, el coeficiente de correlación de Pearson, el coeficiente de correlación de Spearman y la similitud del coseno. Finalmente, los genes 13 y 14 que representan las medidas de similitud de los profesores y las competencias, se definen en el rango [0, 1] representando las 2 métricas consideradas, el índice Jaccard y la función de verosimilitud logarítmica.

### B. Influencia de los diferentes criterios en el Sistema de Recomendación

En esta sección, se evalúa la relevancia de cada uno de los criterios considerados en el SR híbrido presentado, para determinar los factores que pueden resultar más significativos para mejorar las recomendaciones.

En la tabla I se muestra la mejor configuración de pesos encontrada por el AG. En el caso de la configuración del FC que emplea información del estudiante, se puede apreciar que el factor más relevante es la calificación obtenida por los estudiantes (peso de 0.53), seguido por las valoraciones dadas a las asignaturas (peso de 0.25) y la especialidad cursada (peso de 0.22). Estos resultados muestran la relevancia de las calificaciones en la búsqueda

Cuadro I  
MEJOR CONFIGURACIÓN DEL SR OBTENIDA POR EL AG

<b>SR Híbrido</b>	
Peso del FC	0.58
Peso del FBC	0.42
<b>FC (Basado en información del estudiante)</b>	
Valoraciones (métrica sim.)	Distancia Manhattan
Calificaciones (métrica sim.)	Distancia Manhattan
Valoraciones (peso)	0.25
Calificaciones (peso)	0.53
Especialidad (peso)	0.22
Tamaño vecindario	12
<b>FBC (Basado en información de la asignatura)</b>	
Profesores (métrica sim.)	Verosimilitud logarítmica
Competencias (métrica sim.)	Índice de Jaccard
Profesores (peso)	0.54
Competencias (peso)	0.00
Área conoc. (peso)	0.00
Contenido (peso)	0.46

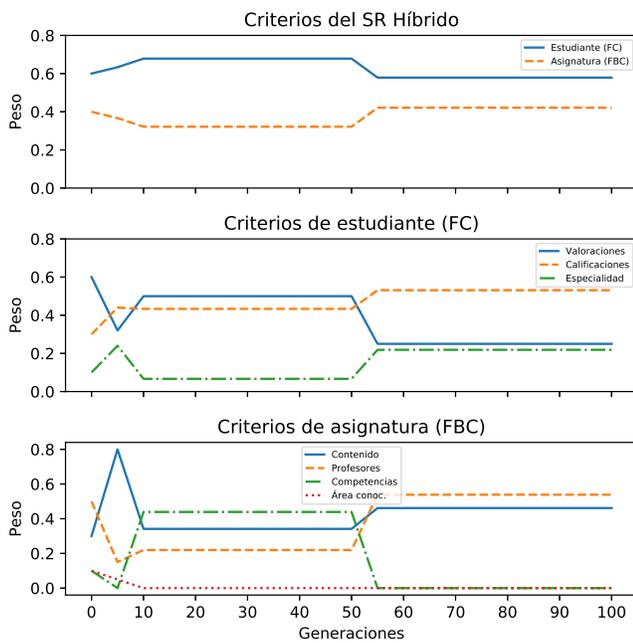


Figura 3. Evolución de los pesos de los criterios en el AG

de estudiantes similares. Así, una asignatura será recomendada a un cierto estudiante si, principalmente, ha sido valorada positivamente por otros estudiantes con unas calificaciones similares a la suya.

Analizando los criterios más relevantes relativos a la información de la asignatura (FBC), se obtiene como factores muy relevantes los profesores que imparten las asignaturas (0.54) y el contenido teórico y práctico de las mismas (0.46); los otros dos criterios (competencias que cubren las asignaturas y el área de conocimiento a la que pertenecen), aparecen como irrelevantes (0.00). Estos resultados, ponen de manifiesto la importancia de los profesores, siendo un factor tan importante como el contenido propio de la asignatura para determinar cómo de similares se perciben dos asignaturas. De esta manera, una asignatura será recomendada a un cierto estudiante si tiene un contenido similar y/o ha sido impartida por el mismo profesorado que otra asignatura que le haya interesado en el pasado.

Finalmente, los pesos asignados por el AG a las estimaciones realizadas por los sistemas FC y FBC son ponderados con 0.58 y 0.42 respectivamente, mostrando la importancia de considerar tanto información del estudiante, como de la asignatura en la recomendación final.

Para estudiar cómo los pesos han ido evolucionando en las sucesivas generaciones del AG, se analiza la evolución del mejor individuo de la población (Figura 3). Se aprecia que los pesos asignados a las recomendaciones realizadas por el FC y por el FBC, comienzan bastante desequilibradas, dando más importancia al FC. Sin embargo, acaban convergiendo en una importancia similar. En el caso de

los pesos asignados a los diferentes criterios considerados en la información del estudiante, se puede apreciar como en las soluciones iniciales el factor de las valoraciones es el más relevante. No obstante, conforme el AG va convergiendo y optimizando el ajuste de parámetros, las calificaciones toman más importancia, pasando valoraciones y especialidad a tener una relevancia similar y menor a las calificaciones. Finalmente, si se estudia la evolución de los pesos asignados por el AG a los diferentes criterios relativos a la información de las asignaturas, se puede apreciar que desde el principio, el área de conocimiento aparece como poco significativa, y es algo que se mantiene hasta el final, mientras que el contenido y los profesores va tomando más relevancia cada vez.

Se puede apreciar que a partir de la generación 60 el peso asignado a los diferentes criterios se mantiene, no siendo mejorados por ninguna otra solución de la población durante el resto de las generaciones. El motivo de que el AG continúe realizando generaciones y optimizando soluciones se debe a que continúa obteniendo mejores soluciones optimizando el resto de parámetros considerados en el AG y configurables en el SR híbrido diseñado, que son las métricas de similitud utilizadas y el tamaño del vecindario.

En la tabla I se muestra las métricas de similitud y el tamaño de vecindario seleccionadas por el AG. En la figura 4, se muestra la evolución del mejor individuo de la población a lo largo de las generaciones para estos valores. En este caso, es interesante resaltar como estos valores van cambiando, a partir de la generación 60, para optimizar las valoraciones proporcionadas por el SR y en consecuencia reducir el RMSE. Se puede apreciar que existe cierta tendencia a que los criterios de valoraciones y calificaciones utilicen la misma métrica. Además, si esta métrica es la medida de similitud del coseno, se necesita

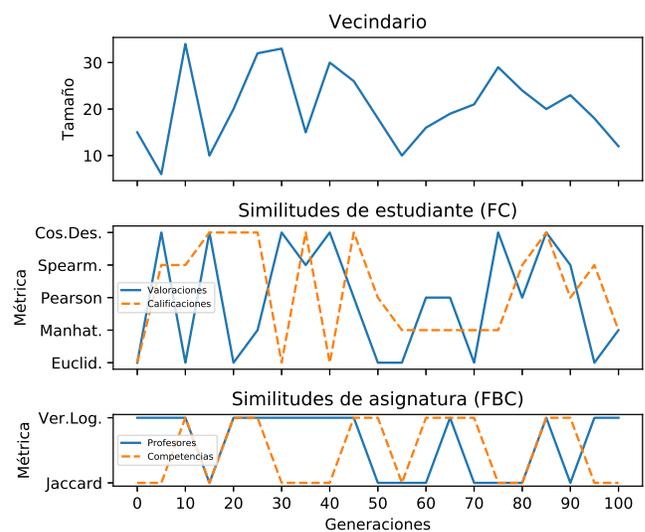


Figura 4. Evolución de las métricas y el vecindario en el AG



un mayor número de vecinos, mientras que para el resto de casos tiende a mantenerse entre 10 y 20.

### C. Comparativa con otros modelos

Para concluir el estudio experimental, se compara el rendimiento del SR híbrido frente al uso de los modelos: FC multi-criterio y FBC multi-criterio con la misma configuración de pesos establecida por el AG, pero sin combinar sus resultados. También se incluye en la comparativa el uso de FC mono-criterio empleando solamente el criterio de las valoraciones (el criterio más ampliamente utilizado en los SR) y FBC mono-criterio empleando solamente la información del criterio del profesorado (el más representativo, de acuerdo a los pesos asignados).

Para llevar a cabo este estudio, se ha ejecutado una evaluación del SR utilizando validación cruzada con 10 *fold* con muestreo estratificado. Las métricas estudiadas son el RMSE, relacionado con cuánto difiere una estimación de la valoración real; la ganancia nDCG (*normalized Discounted Cumulative Gain*), relacionada con la capacidad del SR de ofrecer recomendaciones relevantes; el alcance, que determina el porcentaje de usuarios para los que se pueden obtener recomendaciones; y el tiempo de ejecución que necesita el SR para entrenar el modelo y ofrecer una recomendación.

Los resultados finales pueden verse en la tabla II. El enfoque híbrido obtiene mejores resultados en todas las métricas estudiadas. Aunque al usar más información, tarda algo más que los otros modelos en ejecutarse. De este modo, queda demostrada la importancia de utilizar múltiples criterios en el SR, asignándoles además pesos concretos, así como la de realizar una hibridación de diferentes técnicas.

Cuadro II  
COMPARATIVA ENTRE MODELOS DE SR

Método	RMSE	nDCG	Alcance(%)	Tiempo(s)
SR Híbrido	1.056	0.811	100.00	8.23
FC <sup>1</sup>	1.167	0.806	96.48	7.53
FBC <sup>1</sup>	1.201	0.214	99.36	6.86
FC <sup>2</sup>	1.233	0.798	96.48	5.98
FBC <sup>2</sup>	2.530	0.284	99.36	5.77

<sup>1</sup> multi-criterio, <sup>2</sup> mono-criterio

## VI. CONCLUSIONES

En este trabajo se ha desarrollado un SR aplicado a la recomendación de asignaturas híbrido y multi-criterio. Así mismo, se ha implementado un AG que realiza un ajuste de todos los parámetros utilizados en el SR propuesto para determinar las configuraciones óptimas para el SR. Las pruebas realizadas muestran que considerar varios criterios proporciona mejores resultados, pero que la relevancia de cada uno de ellos debe ser estudiada, ya que no todos los factores resultan igual de relevantes. Además, la consideración de un sistema híbrido, que combina tanto filtrado colaborativo, como basado en contenido, también optimiza los resultados alcanzados.

En un futuro se pretende ampliar las pruebas a otras titulaciones, de forma que se pueda comprobar si se obtienen los mismos resultados, y bajo qué circunstancias se pueden generalizar las conclusiones.

## VII. AGRADECIMIENTO

Este trabajo está financiado por el proyecto de investigación TIN2017-83445-P del Ministerio de Economía y Competitividad y el Fondo Europeo de Desarrollo Regional.

## REFERENCIAS

- [1] C. Romero and S. Ventura. Data mining in education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3(1):12–27, 2013.
- [2] T.N. Huynh-Lv, N. Huu-Hoa, and T.N. Nguyen. Methods for building course recommendation systems. In *Proceedings of the 8th International Conference on Knowledge and Systems Engineering*, pages 163–168, 2016.
- [3] P.-C. Chang, C.-H. Lin, and M.-H. Chen. A hybrid course recommendation system by integrating collaborative filtering and artificial immune systems. *Algorithms*, 9(3):1–18, 2016.
- [4] C. Kim, N. Choi, Y. Heo, and J. Sin. On the development of a course recommender system: A hybrid filtering approach. *Entrée Journal of Information Technology*, 14(2):71–82, 2015.
- [5] C. Vialardi, J. Chue, J.P. Peche, G. Alvarado, B. Vinatea, J. Estrella, and A. Ortigosa. A data mining approach to guide students through the enrollment process based on academic performance. *User Modeling and User-Adapted Interaction*, 21(1-2):217–248, 2011.
- [6] J.W. Han, J.C Jo, H.S. Ji, and H.S. Lim. A collaborative recommender system for learning courses considering the relevance of a learner's learning skills. *Networks Software Tools and Applications*, 19(4):2273–2284, 2016.
- [7] S. Spiegel. *A Hybrid Approach to Recommender Systems based on Matrix Factorization*. Thesis, Tech. University Berlin, 2009.
- [8] A. Parameswaran, P. Venetis, and H. Garcia-Molina. Recommendation systems with complex constraints: A course recommendation perspective. *ACM Transactions on Information Systems*, 29(4):1–33, 2011.
- [9] C.Y. Huang, R.C. Chen, and L.S. Chen. Course-recommender system based on ontology. In *Proceedings of 12th International Conference on Machine Learning and Cybernetics*, pages 1168–1173, 2013.
- [10] L. Zhuhadar, O. Nasraoui, R. Wyatt, and E. Romero. Multi-model ontology-based hybrid recommender system in e-learning domain. In *Proceedings of the International Joint Conferences on Web Intelligence and Intelligent Agent Technology*, pages 91–95, 2009.
- [11] A.A. Kardan, H. Sadeghi, S.S. Ghidary, and M.R.F. Sani. Prediction of student course selection in online higher education institutes using neural network. 65:1–11, 2013.
- [12] J. Sobacki and J.M. Tomczak. Student courses recommendation using ant colony optimization. In *Proceedings of the 2nd Intelligent Information and Database Systems*, volume 5991 of *Lecture Notes in Artificial Intelligence*, pages 124–133, 2010.
- [13] E. Khorasani, Z. Zhenge, and J. Champaign. A markov chain collaborative filtering model for course enrollment recommendations. In *Proceedings of the 4th International Conference on Big Data*, pages 3484–3490. IEEE, 2016.
- [14] R. Wang. *Sequence-based Approaches to Course Recommender Systems*. Thesis, University of Alberta, 2017.
- [15] H. Ma, X. Wang, J. Hou, and Y. Lu. Course recommendation based on semantic similarity analysis. In *Proceedings of 3rd Ieee International Conference on Control Science and Systems Engineering*, pages 638–641, 2017.
- [16] E. Özcan and C. Başaran. A case study of memetic algorithms for constraint optimization. *Soft Computing*, 13(8-9):871–882, 2009.

# Reconocimiento de genes en secuencias de ADN por medio de imágenes.

Luis A. Santamaría C. Sarahí Zuñiga H. Ivo H. Pineda T. María J. Somodevilla Mario Rossainz L.

Fac. Cs Computación. Fac. Cs Computación. Fac. Cs Computación. Fac. Cs Computación. Fac. Cs Computación.

BUAP

BUAP

BUAP

BUAP

BUAP

Puebla, México

Puebla, México

Puebla, México

Puebla, México

Puebla, México

ALULOC\_KAPA@hotmail.com sarahi.zuhe@gmail.com

mariasg@cs.buap.mx

**Resumen**—En los últimos años, el campo del aprendizaje automático ha progresado enormemente al abordar problemas difíciles de clasificación. El problema planteado en este artículo es reconocer secuencias de ADN, reconocer los límites entre exones e intrones utilizando una representación gráfica de secuencias de ADN y métodos recientes de aprendizaje profundo. El objetivo de este trabajo es clasificar secuencias de ADN utilizando una red neuronal convolucional (Convolutional Neural Network CNN). El conjunto de secuencias de ADN utilizado es la base de datos Molecular (Splice-junction Gene Sequences) Data Set que cuenta con 3190 secuencias, disponible en la página de la UCI, con tres clases de secuencias: límite exón-intrón, límite intrón-exón y ninguna. Se utilizó el conjunto de secuencias de ADN utilizado para el reconocimiento fueron 1847 secuencias de una base de datos con 4 tipos de virus de hepatitis C (tipo 1, 2, 3 y 6) tomada del repositorio disponible en la página de ViPR. Para la utilización de las secuencias de ADN se diseñó un método de representación donde cada base nitrogenada es representada en escala de grises para formar una imagen. Las imágenes generadas se utilizaron para entrenar la red neuronal convolucional. Los resultados muestran que una CNN puede hacer la clasificación de secuencias de ADN con un porcentaje de precisión de entrenamiento del 82 %, una precisión de validación del 75 % y una precisión de evaluación del 80.8 %. Se llega a la conclusión de que es posible clasificar las imágenes de secuencias de ADN de la base de datos empleada.

**Palabras clave**—Reconocimiento de genes, Aprendizaje profundo, Redes neuronales convolucionales, Codificación de secuencias de ADN .

## I. INTRODUCCIÓN

Los métodos de aprendizaje automático permiten identificar características que propician la clasificación, análisis y reconocimiento de patrones. En el área de la biología, el uso de métodos de aprendizaje automático, facilitan el reconocimiento de secuencias de ADN. Este trabajo reconoce los genes de ADN previamente procesados para ser representados por una imagen. Este artículo es dividido en secciones, la primera sección es el estado del arte que es el conocimiento previo necesario para el reconocimiento de genes. La segunda sección detalla la metodología que fue utilizada para el análisis de las secuencias de ADN. La tercera y cuarta sección muestran los resultados y las conclusiones obtenidas.

## II. ESTADO DEL ARTE

Los mecanismos o procesos de predicción de genes son aquellos que, dentro del área de la biología computacional,

se utilizan para la identificación algorítmica de trozos de secuencias, usualmente ADN genómico [8], y que son biológicamente funcionales. Esto, especialmente incluye los genes codificantes de proteínas y secuencias reguladoras. La identificación de genes es uno de los primeros y más importantes pasos para entender el genoma de una especie una vez ha sido secuenciado [11].

El ácido desoxirribonucleico (ADN) está compuesto por cuatro moléculas llamadas nucleótidos o bases nitrogenadas: adenina, timina, guanina y citosina [9]. Una molécula completa de ADN o, dicho de otro modo, una secuencia de ADN está compuesta por un alfabeto que contiene las letras de las cuatro bases nitrogenadas.

$$\begin{aligned} \Sigma\{ATGC\} \\ \phi_i = (V_1, V_2, V_3, \dots, V_n) \\ V_i \in \Sigma \end{aligned} \quad (1)$$

Donde una cadena  $\phi$  es una secuencia de ADN formada por elementos del alfabeto  $\Sigma$  y puede definir las características de un organismo vivo, conteniendo toda la información genética en unidades de herencia llamadas genes. Los mecanismos o procesos de predicción de genes son aquellos que, dentro del área de la biología computacional, se utilizan para la identificación algorítmica de trozos de secuencias, usualmente ADN genómico [1], y que son biológicamente funcionales. Esto, especialmente incluye los genes codificantes de proteínas y secuencias reguladoras. La identificación de genes es uno de los primeros y más importantes pasos para entender el genoma de una especie una vez ha sido secuenciado [2].

Las uniones de empalme son puntos en una secuencia de ADN en la que se elimina ADN "inútil" durante el proceso de creación de proteínas en organismos superiores. El problema planteado en este conjunto de datos es reconocer, dada una secuencia de ADN, los límites entre los exones (las partes de la secuencia de ADN retenidas después del corte y empalme) y los intrones (las partes de la secuencia de ADN que se cortan). Este problema consiste en dos subtarefas: reconocimiento de límites de exón / intrón (denominados sitios EI) y reconocimiento de límites de intrón / exón (sitios IE). (En la comunidad biológica, los límites de IE se refieren a los "aceptantes" mientras que los límites de EI se conocen



como “donantes”) [7]. Ambas tareas son complicadas ya que no existe una secuencia estándar para reconocer intrones y exones, razón por la cual es interesante diseñar herramientas que nos ayuden a identificarlos y clasificarlos.

El número de proyectos de investigación sobre genomas actualmente vigentes aumenta a un ritmo acelerado, y proporcionar un catálogo de genes para estos nuevos genomas es un desafío clave. La obtención de un conjunto de genes bien caracterizados, es un requisito básico en los pasos iniciales de cualquier proceso de creación de un genoma. Los métodos de búsqueda de genes computacionales se pueden categorizar libremente como basados en la alineación y en la composición de secuencias o una combinación de ambos. Los métodos basados en la alineación de secuencias se pueden usar cuando se intenta predecir un gen que codifica una proteína para la cual existe un homólogo estrechamente relacionado, este es el enfoque en GeneWise [5] y PROCUSTES [4].

Los algoritmos basados en composición de secuencias (también conocidos como métodos de búsqueda de genes) contienen un modelo probabilístico de estructura génica basado en señales biológicas (sitios de empalme y sitios de inicio / detención de traducción) y propiedades de composición de secuencias funcionales (exones como secuencias codificantes e intrones como secuencias intermedias entre exones e intrones). A diferencia de los métodos basados en la alineación, estos algoritmos se basan sólo en las propiedades intrínsecas de los genes para construir estructuras genéticas predichas. Genscan [10] y Geneid [3] son los dos ejemplos de este enfoque y pueden encontrar genes conocidos y genes nuevos siempre que los genes se ajusten al modelo probabilístico subyacente. Una cadena de ADN es una molécula caracterizada por cuatro bases nitrogenadas Adenina, Timina, Guanina y Citosina [12]. Para mejorar la representación de una cadena de ADN se utilizan secuencias que pueden ser transformadas a representación con valores numéricos o alfabéticos: A (adenina), T (timina), G (guanina) y C (citosina). [10]. Sin embargo, la representación de grandes cantidades de información como secuencias de ADN no hacen sencillo su análisis matemático, esto crea la necesidad de encontrar nuevas formas de representar la información.

En 1988 Lapedes [6] y su equipo de trabajo entrenaron una red neuronal para reconocer genes en secuencias de ADN, lograron una precisión del 91.2% en las uniones de corte y empalme de intrón / exón y del 92.8% en las uniones de empalme de exón / intrón. Lo que dio origen a plantear el uso de redes neuronales convolucionales para resolver este mismo problema de clasificación. Este trabajo consistió en buscar una nueva forma de representar secuencias de ADN para su análisis, como ya se ha hecho referencia, existen actualmente diferentes métodos para reconocer genes, pero estas representaciones complican su análisis. La propuesta que presentamos es generar imágenes a partir secuencias de ADN y someterlas a análisis por técnicas de aprendizaje profundo, en específico a redes neuronales convolucionales; utilizadas para la clasificación de imágenes. Actualmente no se ha encontrado un modelo matemático que resuelva el proceso de clasificación

por redes neuronales, pero sus resultados llegan a ser tan altos que superan el 99% en algunos casos [1].

## II-A. Red Neuronal Convolutiva (CNN)

En los últimos años, el campo del aprendizaje automático ha progresado enormemente al abordar problemas de clasificación, identificación y reconocimiento de patrones. En particular, se ha encontrado que un tipo de modelo llamado red neuronal convolutiva CNN (Convolutional Neural Network) por sus siglas en inglés, que logra un rendimiento razonable en tareas de reconocimiento visual de hardware, igualando o superando el rendimiento humano en algunos dominios [11]. Una CNN es un algoritmo para el aprendizaje automático en el que un modelo aprende a realizar tareas de clasificación directamente a partir de imágenes, videos o sonidos. Las CNNs son especialmente útiles para localizar patrones en imágenes con el objetivo de reconocer objetos, caras y escenas. Aprenden directamente a partir de los datos de imágenes, utilizando patrones para clasificar las imágenes y eliminar la necesidad de una extracción manual de características.

Inception-v3 está diseñado para el desafío de Reconocimiento Visual, ésta es una tarea estándar en visión artificial, donde los modelos intentan clasificar imágenes completas en 1000 clases de ImageNet. TensorFlow es una herramienta para el aprendizaje automático. Si bien contiene una amplia gama de funcionalidades, TensorFlow está diseñado principalmente para modelos de redes neuronales profundas. Los modelos modernos de reconocimiento de imágenes tienen millones de parámetros; entrenarlos desde cero requiere una gran cantidad de datos de entrenamiento etiquetados y una gran cantidad de potencia de cálculo (cientos de horas de GPU o más). El aprendizaje de transferencia es una técnica que ataja mucho de esto tomando una pieza de un modelo que ya ha sido entrenado en una tarea relacionada y reutilizándola en un nuevo modelo, en la figura 1 se muestra un ejemplo de una CNN, los filtros se aplican a cada imagen de entrenamiento con diferentes resoluciones, y la salida de cada imagen convolucionada se usa como entrada para la capa siguiente [2]. Aunque no es igual de preciso en comparación a la capacitación del modelo completo, es sorprendentemente eficaz para muchas aplicaciones, funciona con cantidades moderadas de datos de capacitación (miles, no millones de imágenes etiquetadas) y se puede ejecutar en tan solo treinta minutos en una computadora portátil sin una GPU [11].

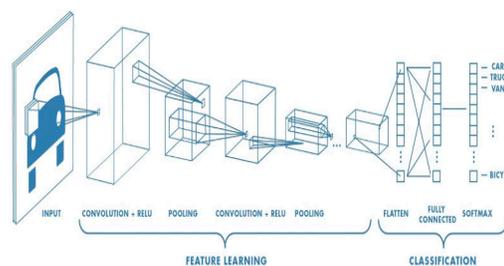


Figura 1. Ejemplo de una Red Neuronal Convolutiva

### III. METODOLOGÍA

En esta sección se describe detalladamente como se generaron imágenes a partir de secuencias de ADN y su posterior uso en el entrenamiento de una red neuronal convolucional para clasificación de tres clases de secuencias. En esta etapa del proyecto consistió en convertir las secuencias de ADN a representaciones gráficas para entrenar una CNN. Un aspecto importante que se ha considerado este trabajo es que las CNN son utilizadas para el reconocimiento de patrones y clasificación de imágenes. Las secuencias de ADN de manera general son representadas por letras: A usada para la adenina, G para la guanina, C para la citosina y T para la timina, sin embargo, una CNN no está establecida para procesar información bajo este formato, por esta razón se diseñó una representación gráfica de las secuencias. El primer paso fue asignar un color en escala de grises a cada una de las letras como se muestra en el Cuadro I. Las escalas de grises va de 0 que representa negro, a 1 que represa el blanco, de tal manera que los colores intermedios resultantes son tonalidades de gris para mostrar un mejor contraste. Lo segundo fue hacer

Cuadro I  
REPRESENTACIÓN POR COLOR DE LAS BASES NITROGENADAS.

Base Nitrogenada	Valor de gris
A	0
C	0.3
G	0.7
T	1

que las secuencias pudieran ser representadas por una imagen específica a cada una. Para lograr esto se utilizó una matriz de dimensión 60 X 60, donde el valor 60 coincide con el número de bases nitrogenadas de todas las secuencias de la base de datos. Cada secuencia fue colocada en la primera fila y copiada en el resto de las filas hasta tener 60 en total, así el resultado final es una imagen con barras en la escala de grises como la que se muestra en la Figura 3, cada una de las imágenes obtenidas es específica para cada instancia de la base de datos como se observa en la Figura 2. En total se obtuvieron 3190 imágenes.

```

1 CCAGCTGCATCACAGGAGGCCAGCGAGCAGGTCTGTTC AAGGGCCTTCGAGCCAGTCTG
2 CCAGCTGCATCACAGGAGGCCAGCGAGCAGGTCTGTTC AAGGGCCTTCGAGCCAGTCTG
3 CCAGCTGCATCACAGGAGGCCAGCGAGCAGGTCTGTTC AAGGGCCTTCGAGCCAGTCTG
.
.
.
60 CCAGCTGCATCACAGGAGGCCAGCGAGCAGGTCTGTTC AAGGGCCTTCGAGCCAGTCTG
    
```

Figura 2. Secuencia ADN a codificar

#### III-A. Utilización de CNN a secuencias de ADN

En esta subsección se describe cómo se entrenó una CNN con las imágenes representativas de cada secuencia. Se utilizó



Figura 3. Imagen asociada

una CNN InceptionV3 a la que se le aplicó la transferencia de aprendizaje profundo para categorizar el reconocimiento de tres clases de secuencias de ADN: reconocimiento de límites de exón / intrón (denominados sitios EI), reconocimiento de límites de intrón / exón (sitios IE) y reconocimiento de ninguno de los dos anteriores (N).

Una vez que se logró representar a las secuencias de ADN como imágenes se utilizó una CNN y con la librería de software TensorFlow se construyó un modelo de clasificación basado en una red neuronal convolucional pre-entrenada. Se utilizaron CNNs InceptionV3 a las que se les aplicó la transferencia de aprendizaje profundo para categorizar el reconocimiento de una base de datos con cuatro clases de secuencias de ADN: virus de Hepatitis C tipo 1, 2, 3 y 6 y el reconocimiento de otra base de datos con tres clases de límites de exón / intrón (denominados sitios EI), reconocimiento de límites de intrón / exón (sitios IE) y reconocimiento de ninguno de los dos anteriores (N). Para ajustar el modelo a nuestro problema se entrenaron las últimas capas de las redes con instancias obtenidas de las bases de datos, ambas redes fueron entrenadas en 4000 pasos.

Primero se entrenó la CNN para hacer la clasificación de los 4 tipos de virus de Hepatitis, posteriormente se entrenó una CNN con solamente 2 clases: EI e IE y por último se entrenó otra CNN con todas las clases de la base de datos: EI, IE y N para comparar los resultados de las últimas dos neuronas.

### IV. RESULTADOS

Los resultados de clasificación para la CNN entrenada con la base de datos de los cuatro tipos de virus de Hepatitis C muestran una precisión de evaluación 95 % con 145 imágenes probadas y al terminar el paso (k) 4000 la precisión de entrenamiento fue del 94.5 % y la precisión de validación del 95 % como se observa en la figura 4. El comportamiento decreciente de la entropía durante el entrenamiento, se aprecia en la figura 5 .

Al usar una CNN con las clases EI e IE se obtiene una precisión de evaluación del 80.8 % con 177 imágenes de prueba y al terminar el paso (k) 4000 la precisión de entrenamiento es del 82 % y la precisión de validación del 75 %. En la Figura 6 se muestra como la exactitud de entrenamiento (naranja) y validación (azul) va cambiando en cada paso y en la Figura 7 se muestra como la entropía disminuye con el incremento de los pasos durante el entrenamiento. Por otro lado, los resultados de la segunda CNN donde se utilizaron las tres clases de la base de datos muestran una precisión de evaluación

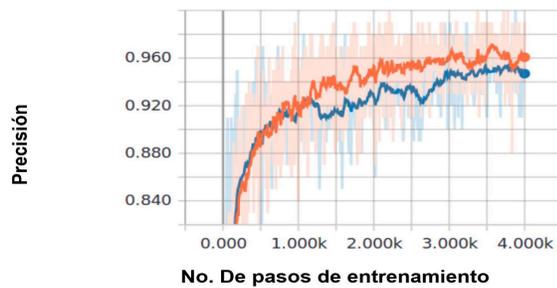


Figura 4. CNN con las clases de virus de Hepatitis C tipo 1, 2, 3 y 6. Naranja: precisión de entrenamiento. Azul: precisión de validación después de 4000 pasos (k).

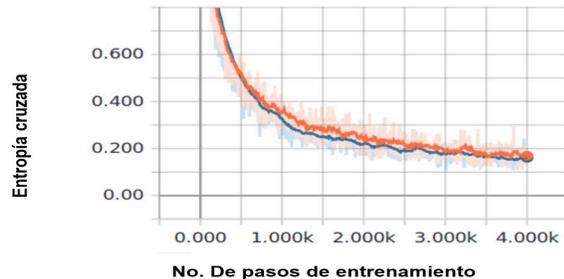


Figura 5. Entropía cruzada de la CNN con las clases de virus de Hepatitis C tipo 1, 2, 3 y 6 después de 4000 pasos (k). Trazo superior: entrenamiento. Trazo inferior: validación.

de 57.5% con 301 imágenes y al terminar el paso 4000 la precisión de entrenamiento 69% y la precisión de validación con un 56% como se aprecia en la Figura 8. En la Figura 9 se muestra los cambios de la entropía en cada etapa del entrenamiento.

## V. CONCLUSIONES

Los resultados obtenidos de la CNN entrenada con la base de datos de virus de Hepatitis C sugieren que la metodología de aprendizaje automático empleada en este trabajo es adecuada para la clasificación de las imágenes generadas a partir de las secuencias de ADN, mostrando importantes y altos porcentajes de precisión de evaluación, precisión de entrenamiento y la precisión de validación. Estos resultados nos llevaron a realizar los siguientes experimentos para el reconocimiento de exones e intrones en la siguiente base de datos. Para este caso las CNN muestran que los porcentajes de precisión de validación son menores en comparación a los de una red neuronal tomando como referencia el trabajo de Lapedes [6]. La importancia del trabajo es que se presentan resultados favorables para seguir explorando el uso de las redes neuronales convolucionales utilizando la representación de las secuencias de ADN como imágenes, un método de codificación sencillo y práctico.

En este trabajo se ha logrado realizar clasificación de secuencias de ADN usando una CNN y los resultados demuestran que las CNN son capaces de realizar esta clasificación hasta con un 80.8% de precisión de evaluación para el experimento con las clases IE e EI y el 57.5% para el experimento con

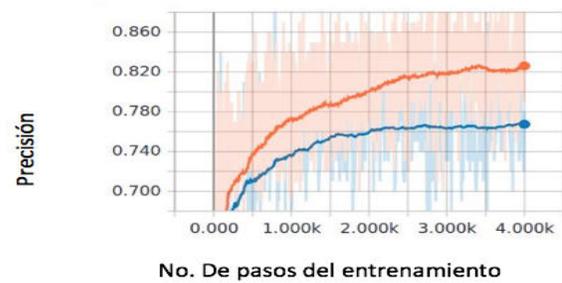


Figura 6. CNN con las clases IE y EI. Naranja: precisión de entrenamiento. Azul: precisión de validación después de 4000 pasos (k).

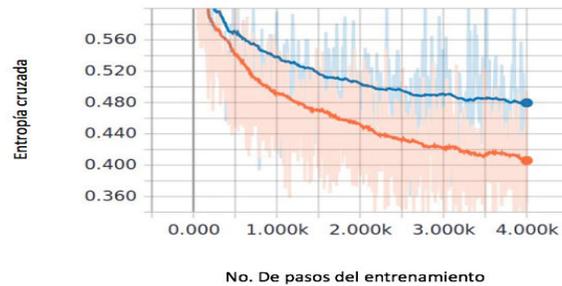


Figura 7. Entropía cruzada de la CNN con las clases IE y EI después de 4000 pasos (k). Naranja: entrenamiento. Azul: validación.

las clases IE, EI y N. Resultados similares se pueden observar en la precisión de entrenamiento y validación de las Figuras 6 y 8. En el caso de los cuatro tipos de hepatitis se logran resultados de hasta 94.5% de precisión de evaluación.

La diferencia entre los resultados obtenidos para los experimentos con dos y tres clases se puede justificar que al incrementar el número de clases se incrementa la entropía Figuras 7 y 9. La entropía cruzada es una métrica que puede utilizarse para reflejar la precisión de los pronósticos probabilísticos y está estrechamente vinculada con la estimación por máxima verosimilitud. La entropía cruzada es una función que permite evaluar el resultado de la clasificación en vez de utilizar la métrica del error cuadrático medio, el valor de la entropía cruzada permite evaluar el progreso del proceso de aprendizaje de la información [1].

Por otro lado, se habla de que la transferencia de aprendizaje es buena cuando se disponen de pocas imágenes para entrenar la red y que permite llegar a resultados aceptables en la mayoría de los casos, sin embargo, todavía es posible mejorar aún más la precisión de validación y entrenamiento y disminuir la entropía si se entrena una red neuronal desde cero, es decir se debe contar con una base de datos de millones de instancias y un equipo de cómputo con GPU para entrenar esta red pero seguramente ofrecerá mejores resultados que la CNN pre-entrenada que utilizamos para este trabajo.

En conclusión, se puede afirmar que una red neuronal convolucional del modelo InceptionV3 es capaz de clasificar secuencias de ADN si la secuencia es procesada y transformada a una imagen, sin embargo, los porcentajes de exactitud se pueden mejorar si se entrena una CNN con una base de



Figura 8. CNN con las clases IE, EI y N. Naranja: precisión de entrenamiento. Azul: precisión de validación después de 4000 pasos (k).

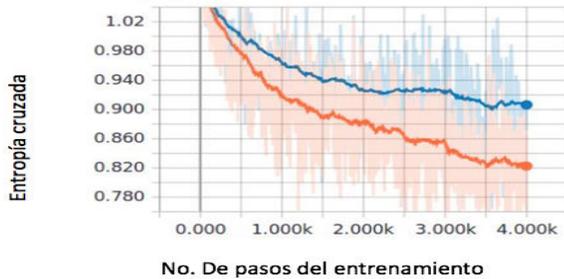


Figura 9. Entropía cruzada de la CNN con las clases IE, EI y N después de 4000 pasos (k). Naranja: entrenamiento. Azul: validación.

secuencias más grande.

### Reconocimientos

Los autores agradecen al Consejo Nacional de Ciencia y Tecnología (CONACyT) de México, a la Benemérita Universidad Autónoma de Puebla la cual a través de la Facultad de Ciencias de la Computación han brindado el apoyo necesario para la realización y presentación del presente trabajo.

### REFERENCIAS

- [1] How to retrain an image classifier for new categories. [https://www.tensorflow.org/tutorials/image\\_retraining](https://www.tensorflow.org/tutorials/image_retraining). Accessed: 2018-05-28.
- [2] Mathworks (2018). deep learning. <https://la.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>. Accessed: 2018-05-27.
- [3] Jonas S Almeida and Susana Vinga. Universal sequence map (usm) of arbitrary discrete sequences. *BMC bioinformatics*, 3(1):6, 2002.
- [4] Chris Burge and Samuel Karlin. Prediction of complete gene structures in human genomic dna1. *Journal of molecular biology*, 268(1):78–94, 1997.
- [5] Mikhail S Gelfand, Andrey A Mironov, and Pavel A Pevzner. Gene recognition via spliced sequence alignment. *Proceedings of the National Academy of Sciences*, 93(17):9061–9066, 1996.
- [6] A Lapedes, Christopher Barnes, Christian Burks, R Farber, and K Sitotkin. Application of neural networks and other machine learning algorithms to dna sequence analysis. Technical report, Los Alamos National Lab., NM (USA), 1988.
- [7] Michiel O Noordewier, Geoffrey G Towell, and Jude W Shavlik. Training knowledge-based neural networks to recognize genes in dna sequences. In *Advances in neural information processing systems*, pages 530–536, 1991.
- [8] Christos A Ouzounis. Rise and demise of bioinformatics? promise and progress. *PLoS computational biology*, 8(4):e1002487, 2012.
- [9] Arturo Panduro. *Biología molecular en la clínica*. McGraw-Hill Interamericana, 2009.
- [10] Genís Parra, Enrique Blanco, and Roderic Guigó. Geneid in drosophila. *Genome research*, 10(4):511–515, 2000.
- [11] SL Salzberg, DB Searls, and S Kasif. Computational gene prediction using neural networks and similarity search. *Computational Methods in Molecular Biology*, 32:109, 1998.
- [12] Zhu-Jin Zhang. Dv-curve: a novel intuitive tool for visualizing and analyzing dna sequences. *Bioinformatics*, 25(9):1112–1117, 2009.

**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 2:  
MODELOS DESCRIPTIVOS







# Reglas de Asociación en Datos Multi-Instancia mediante Programación Genética Gramatical

José María Luna  
 Depto. Informática y Análisis Numérico,  
 Universidad de Córdoba  
 Email: jmluna@uco.es

Oscar Reyes  
 Depto. Informática y Análisis Numérico,  
 Universidad de Córdoba  
 Email: ogreyesp@gmail.com

María José del Jesus  
 Depto. Informática,  
 Universidad de Jaén  
 Email: mjjesus@ujaen.es

Sebastián Ventura  
 Depto. Informática y Análisis Numérico,  
 Universidad de Córdoba  
 Email: sventura@uco.es

**Abstract**—El estado del arte actual en minería de reglas de asociación es bastante prometedor en cuanto a la extracción automática de relaciones de interés entre patrones o elementos de grandes bases de datos. Por lo general, los datos se encuentran representados en forma tabular, donde cada fila define inequívocamente un registro de datos u objeto en el dominio de la aplicación. En ocasiones, estos registros de datos no pueden o deben ser considerados de forma aislada (por ejemplo, datos que comprenden hábitos de compra de clientes de manera que diferentes registros pueden describir un mismo cliente) y, por tanto, el problema no puede ser abordado como un problema de minería de reglas de asociación tradicional. Un primer intento de resolver este problema consideró un enfoque determinista sobre dominios discretos y requiriendo analizar todo el espacio de búsqueda (el tiempo de computo es exponencial respecto al número de elementos). Sin embargo, cuando nos enfrentamos a un problema real, la información se encuentra generalmente definida en dominios continuos, se requieren resultados en el menor tiempo posible, y se necesita satisfacer las expectativas de los usuarios (los resultados deben coincidir con la forma deseada). En este sentido, el objetivo de este trabajo es solucionar estos desafíos mediante un algoritmo de programación genética gramatical. Tanto sus fortalezas como defectos se analizan sobre un conjunto variado de datos en el estudio experimental.

## I. INTRODUCCIÓN

Desde que se produjo la revolución digital, la cantidad de información que se almacena en cada dominio de aplicación ha crecido a un ritmo exponencial. En este sentido, se requiere que las diferentes técnicas de minería de datos mejoren su eficiencia para poder tratar con tales conjuntos masivos de datos en un tiempo considerable. Una de las tareas de minería de datos que se ha visto claramente afectada por la dimensionalidad de los datos es la minería de reglas de asociación (ARM por su término en inglés) [1]. Considerando un conjunto de datos con  $k$  elementos, el espacio de búsqueda en el que ARM debe buscar soluciones incluye un total de  $3^k - 2^{k+1} + 1$  reglas de asociación diferentes obtenidas sobre un total de  $2^k - 1$  patrones o combinaciones de elementos.

Incluso cuando se trata de un problema realmente complejo, especialmente para grandes conjuntos de datos, diferentes investigadores han propuesto algoritmos de ARM realmente

eficientes. Dichas propuestas fueron especialmente relevantes gracias a las arquitecturas paralelas actuales y *frameworks* [?]. En este sentido, el problema de ARM se puede considerar como resuelto desde el punto de vista del rendimiento [?]. Sin embargo, el creciente interés en el almacenamiento de datos ha causado no solo un crecimiento en la dimensionalidad de los datos, sino también en la representaciones de dichos datos. A modo de ejemplo, consideremos una cadena de supermercados que quiere extraer conocimiento útil sobre los hábitos de compra de sus clientes para tomar decisiones correctas. Supongamos que la información se almacena en una tabla tradicional (cada fila indica una transacción diferente). Aquí, cada cliente tendrá un peso específico en la descripción de datos con respecto al número de transacciones que representa y, por lo tanto, esta representación de datos desvía el conocimiento extraído según el tipo de cliente (los clientes frecuentes son más importantes que los clientes esporádicos). Consideremos ahora que cada cliente se almacena como un ejemplo que comprende un número indefinido de transacciones, y los datos se describen sobre conjunto de ejemplos en lugar de sobre el conjunto de transacciones. De esta forma, el conocimiento extraído revela información explícita sobre los hábitos de los clientes independientemente de la cantidad de transacciones que realiza cada cliente. Esto implica que la forma en que se estructuran los datos es esencial para proporcionar el conocimiento correcto.

Este almacenamiento de información está por tanto relacionado con *multiple-instance learning* (MIL) [4], una generalización del aprendizaje supervisado tradicional. En MIL, los ejemplos son ambiguos y un solo ejemplo puede tener muchas instancias alternativas que lo describen. Esta ambigüedad se analizó recientemente [5] desde una perspectiva de descripción de datos mediante ARM sobre estructuras de datos de múltiples instancias. Sin embargo, este primer intento se basó en una metodología de búsqueda exhaustiva para establecer las bases en esta nueva representación para análisis descriptivo de datos y no se prestó atención al tiempo de ejecución, la metodología, el dominio de la aplicación y las

preferencias de los usuarios.

El objetivo de este trabajo es proponer un nuevo algoritmo de ARM para trabajar sobre datos de multi-instancia. El enfoque propuesto, conocido como MIAR-GePro, se basa en una metodología de programación genética gramatical y tiene como objetivo mejorar el estado del arte en este campo. MIAR-GePro puede trabajar tanto en dominios discretos como continuos, representando una importante ventaja respecto a la propuesta existente (requiere una discretización previa al proceso de extracción). Además, el modelo evolutivo propuesto es capaz de extraer reglas de asociación en un solo paso (la propuesta existente requiere extraer primero todos los patrones frecuentes y, a posteriori, obtener reglas de asociación sobre dichos patrones). Finalmente, los resultados obtenidos mediante MIAR-GePro están restringidos de acuerdo a una gramática predefinida por el usuario, por lo que es éste usuario final quien tiene la capacidad de definir la forma de las reglas que desea obtener. Todas estas características, así como algunos inconvenientes de esta propuesta se analizan en la etapa experimental al considerar un conjunto variado de datos.

El presente documento está organizado de la siguiente manera. La sección II presenta las definiciones más relevantes y el trabajo relacionado. La sección III describe el algoritmo MIAR-GePro propuesto. La sección IV presenta los conjuntos de datos utilizados en los experimentos, la configuración seguida, así como los resultados obtenidos. Finalmente, algunas observaciones finales se describen en la sección V.

## II. PARELIMINARES

En esta sección se describe por primera vez el problema de datos multi-instancia. A continuación, se define la tarea de minería de regla de asociación (ARM por su término en inglés) y se analiza el primer intento de extraer reglas de asociación en datos multi-instancia.

### A. Datos Multi-Instancia

El problema de aprendizaje sobre datos multi-instancia fue introducido por primera vez por *Dietterich et al.* [4] en 1997 en el contexto de la predicción del comportamiento de diferentes fármacos. En este dominio de aplicación, los ejemplos son ambiguos y pueden incluir múltiples instancias alternativas que lo describen. De manera formal, supongamos que cada ejemplo  $e_i$  puede tener  $v_i$  variantes  $e_{i,1}, e_{i,2}, \dots, e_{i,v_i}$ . Cada una de estas variantes estará representada por un vector de características distintas  $V(e_{i,j})$ , por lo que un ejemplo completo  $e_i$  se representa por lo tanto como un conjunto de vectores de características en la forma  $\{V(e_{i,1}), V(e_{i,2}), \dots, V(e_{i,v_i})\}$ . Incluso cuando este problema se ha aplicado generalmente a las tareas de aprendizaje supervisado [6], realizar un análisis descriptivo de ese tipo de datos es de gran interés en muchos dominios. Considerando el conocido problema de análisis de la cesta de la compra, un único cliente puede describir diferentes compras, por ejemplo, en días diferentes de un mes. Como resultado, cada ejemplo (un cliente específico) incluye un número indefinido de registros (diferentes compras). En este escenario, el problema se puede definir como el análisis de

un conjunto de datos en el que los datos se representan como multi-instancias, y se pueden aplicar diferentes hipótesis de trabajo.

La hipótesis de trabajo más simple fue propuesta por *Dietterich* [4], y considera que un determinado ejemplo se cumple si al menos una de las instancias incluidas en dicho ejemplo es satisfecha. En la minería de patrones, el problema se modela como encontrar un patrón  $P$  en el que  $\exists j : P \subset V(e_{i,j})$  para una gran cantidad de ejemplos  $e_i$ . Teniendo en cuenta esta hipótesis en el análisis de la cesta de mercado, su objetivo es encontrar artículos (o conjunto de artículos) comprados al menos una vez por un gran número de clientes. Aquí, el objetivo es descubrir cuáles son los productos más populares o qué productos generalmente compran los clientes a la vez.

Múltiples autores han propuesto diferentes hipótesis de trabajo para tratar el problema de multi-instancia. *Weidmann et al.* [7] definió dos tipos adicionales de hipótesis que son casos especiales del propuesto por *Dietterich*. En la primera de estas hipótesis adicionales, el problema se modela como el de encontrar un patrón  $P$  en el que  $\sum_{j=1}^{v_i} P \subset V(e_{i,j}) \geq m$  para un número alto de ejemplos  $e_i$ . Centrándose en el análisis de la cesta de la compra, esta hipótesis es realmente útil para determinar qué artículos (o conjunto de artículos) generalmente se compran más de  $m$  veces por un gran número de clientes. Aquí, no solo es importante conocer productos populares, sino que también se requiere que tales productos sean generalmente comprados por cada uno de los clientes. Finalmente, el segundo tipo de hipótesis definido por *Weidmann et al.* [7] establece que un patrón  $P$  se satisface con un número determinado de instancias en un ejemplo, y este número está entre un valor mínimo  $m$  y un valor máximo  $o$ . En otras palabras,  $o \geq \sum_{j=1}^{v_i} P \subset V(e_{i,j}) \geq m$  en una gran cantidad de ejemplos  $e_i$ . Volviendo al análisis de la cesta de la compra, esta hipótesis es esencial para conocer el conjunto de clientes que consumen un producto específico un número predefinido de veces (dando un valor umbral mínimo y máximo).

### B. Minería de Reglas de Asociación

La tarea de ARM fue definida formalmente por *Agrawal et al.* [8] en los años 90. Esta tarea tiene como objetivo extraer implicaciones de la forma *Antecedente*  $\rightarrow$  *Consecuente* que sean de especial interés y desconocidas. Tanto *Antecedente* ( $A$ ) and *Consecuente* ( $C$ ) representan conjuntos disjuntos de elementos. De manera formal, se define  $I = \{i_1, i_2, \dots, i_n\}$  como el conjunto de  $n$  elementos incluidos en un conjunto de datos  $\Omega$ , y  $T = \{t_1, t_2, \dots, t_m\}$  como el conjunto de transacciones o registros que cumplen  $\forall t \in T : t \subseteq I \in \Omega$ . Una regla de asociación es una implicación de la forma  $A \rightarrow C$  donde  $A \subset I$ ,  $C \subset I$ , y  $A \cap C = \emptyset$ . La frecuencia (también conocida como soporte) de una regla  $A \rightarrow C$  es definida como el porcentaje de transacciones en las que se cumple  $A \cup C \subseteq t : t \in T$ . Este hecho se ha definido también en términos absolutos como el número de transacciones en las que aparece  $A \cup C$ , es decir,  $|\{\forall t \in T : A \cup C \subseteq t, t \subseteq I \in \Omega\}|$ . El significado de una regla de asociación es que si el antecedente



$G = (\Sigma_N, \Sigma_T, P, S)$  con:

$S$	=	Regla
$\Sigma_N$	=	{Regla, Antecedente, Consecuente, Condiciones, Condición, Condición_Nominal, Condición_Numérica}
$\Sigma_T$	=	{'Y', 'Atributo', 'valor', '=', '>', '<='}
$P$	=	{Regla = Antecedente, Consecuente ; Antecedente = Condiciones; Consecuente = Condiciones; Condiciones = 'Y', Condiciones, Condición   Condición ; Condición = Condition_Nominal   Condición_Numérica ; Condición_Nominal = 'Atributo', '=', 'valor' ; Condición_Numérica = 'Atributo', '>', 'valor'   'Atributo', '<', 'valor';}

Fig. 1. Gramática de contexto libre que representa reglas de asociación expresadas en notación BNF

de la regla se cumple, entonces es bastante probable que el consecuente de dicha regla también se cumpla.

El uso de ARM sobre representaciones de datos no estándar, por ejemplo datos multi-instancia, han sido recientemente estudiados debido a su relevancia. En un conjunto de datos multi-instancia  $\Omega$ , cada bolsa de instancias o ejemplos  $e_i \in \Omega$  comprende un número variado  $l$  de transacciones o instancias, es decir,  $e_i = \{t_{i,1}, t_{i,2}, \dots, t_{i,l}\}$ . Cada instancia única  $t_{i,j}$  se define como un subconjunto de elementos tales que  $t_{i,j} \in e_i : j \leq l, t_{i,j} \subseteq I$ . La principal entre ARM clásica y la basada en multi-instancias radica en las medidas de calidad utilizadas para determinar el interés de las soluciones. En la forma más simple, una regla de asociación  $A \rightarrow C$  cumplirá un ejemplo  $e_i$  si y sólo si al menos una de sus instancias  $t_{i,j} \in e_i$  es satisfecha por la regla, es decir,  $A \cup C \subseteq t_{i,j} : t_{i,j} \in e_i$ .

La métrica conocida como soporte de una regla  $A \rightarrow C$  se define como el número de ejemplos que la cumplen, es decir,  $|\{\forall e_i \in \Omega : A \cup C \subseteq t_{i,j} \in e_i\}|$ . El soporte puede definirse también en su forma relativa al tamaño del conjunto de datos tal que  $|\{\forall e_i \in \Omega : A \cup C \subseteq t_{i,j} \in e_i\}|/|\Omega|$ . Una característica importante del soporte en datos multi-instancia es la posibilidad de que tanto  $A$  como  $C$  satisfagan todas las transacciones, pero si se analizan juntas no satisfacen ninguna transacción. Esta afirmación no es posible en ARM clásico ya que considera cada transacción como una sola instancia. Centrándonos en otra medida de la calidad de las reglas en problemas multi-instancia, la confianza se define como la proporción del número de ejemplos que incluyen  $A$  y  $C$  entre todos los ejemplos que comprenden  $A$ . Otra métrica ampliamente utilizada entre las muchas existentes en ARM [10] es conocida como *lift* y permite establecer cuántas veces ocurren  $A$  y  $C$  juntas más a menudo de lo que se esperaría si fueran estadísticamente independientes, es decir  $Lift(A \cup C) = Soporte(A \cup C) / (Soporte(A) \times Soporte(C))$ .

### III. MIAR-GEPRO

El algoritmo propuesto, conocido como MIAR-GePro (por sus siglas en inglés de *Multiple-Instance Association Rule Genetic Programming*), incorpora una gramática libre de contexto que se adapta tanto al problema en cuestión como al conocimiento subjetivo del usuario. Esta gramática permite predefinir la forma de las soluciones y, por lo tanto, el espacio

de búsqueda se reduce a aquellas soluciones que cumplen con la gramática.

a) **Criterio de codificación:** en programación genética gramatical [11] cada solución al problema bajo estudio está representada por un genotipo (árbol de derivación basado en el lenguaje definido por una gramática  $G$ ) y un fenotipo (significado de la estructura del árbol). Una gramática libre de contexto se define como  $(\Sigma_N, \Sigma_T, P, S)$  donde  $\Sigma_T$  representa el alfabeto de los símbolos terminales y  $\Sigma_N$  el alfabeto de los símbolos no terminales, siendo ambos conjuntos disjuntos, es decir,  $\Sigma_N \cap \Sigma_T = \emptyset$ . Además,  $P$  establece el conjunto de reglas de producción que se utilizan para codificar una solución, y estas reglas de producción deben comenzar desde el símbolo inicial  $S$ . Una regla de producción se define como una regla  $\alpha \rightarrow \beta$ , donde  $\alpha \in \Sigma_N$ , y  $\beta \in \{\Sigma_T \cup \Sigma_N\}^*$ . Como se describió anteriormente, se aplica una serie de reglas de producción del conjunto  $P$  para obtener una solución que se representa como un árbol donde los nodos internos contienen solo símbolos no terminales y las hojas contienen solo terminales.

La Figura 1 muestra la gramática de contexto libre propuesta en el algoritmo MIAR-GePro. En esta gramática, el símbolo inicial  $S$  se representa con el término Rule (raíz del árbol de derivación), el cual siempre tiene como nodos hijos el antecedente y el consecuente de la regla. Estos dos nodos secundarios (antecedente y consecuente) pueden ser expandidos en una sola condición o un conjunto de condiciones que incluyen características tanto discretas como continuas. Como resultado y considerando la gramática propuesta (ver Figura 1), se obtiene el siguiente lenguaje de la gramática  $L(G) = \{(Y \text{ Condicion})^n \text{ Condicion} \rightarrow (Y \text{ Condicion})^m \text{ Condicion}, n \geq 0, m \geq 0\}$  que cualquier solución válida debe satisfacer.

b) **Proceso de evaluación:** El proceso clave de cualquier algoritmo evolutivo es la evaluación de las soluciones, el cual guía el proceso de búsqueda a través de soluciones prometedoras dentro del espacio de búsqueda. Aunque se pueden utilizar muchas hipótesis de trabajo para evaluar las soluciones de MIAR-GePro (varias hipótesis se describieron en la sección II-A), en este trabajo hemos considerado la hipótesis tradicional de *Dietterich* donde un ejemplo específico se satisface si y sólo si se cumple al menos una instancia dentro de dicho ejemplo. Así pues, el número máximo de registros

que puede satisfacer una regla (solución al problema) vendrá dado por el número de ejemplos y no por el número total de instancias (considerando todos los ejemplos).

c) **Operadores genéticos:** MIAR-GePro incluye dos operadores genéticos para generar nuevas soluciones en cada generación del proceso evolutivo. Estos dos operadores se basan en el cruce y la mutación selectiva propuestos por Whigham [12]. El operador de cruce permite crear nuevas soluciones intercambiando subárboles aleatorios a partir de dos padres de forma que se garantizan soluciones correctas de acuerdo al lenguaje de la gramática (ver Figure 1). Para evitar el crecimiento incontrolado, se utiliza como parámetro una profundidad máxima de árbol. Con respecto al operador de mutación, éste selecciona de forma aleatoria un nodo no terminal del árbol y genera un nuevo subárbol a partir de él.

d) **Esquema evolutivo:** MIAR-GePro se basa en un algoritmo evolutivo generacional clásico con elitismo (ver Algoritmo 1). La élite está formada por un número máximo predefinido de soluciones, que son las soluciones que deben devolverse al finalizar la ejecución del algoritmo (ver línea 16, Algoritmo 1). Inicialmente, se genera aleatoriamente una población de individuos (soluciones en forma de árboles) (ver línea 3, Algoritmo 1) al considerar la gramática propuesta de contexto libre  $G$  y los atributos dentro del conjunto de datos  $\Omega$ . Una vez que los individuos son evaluados con respecto a algunas medidas de calidad (ver *Evaluation Procedure*, líneas 17 a 44, Algoritmo 1) se ejecuta el ciclo principal, que comprende las siguientes operaciones (ver líneas 7 a 15, Algoritmo 1): (a) se selecciona un conjunto de individuos de la población  $pop$  para actuar como padres por medio de un selector por torneo de tamaño 2; (b) el conjunto de padres se cruzan y mutan para formar nuevos individuos (incluidos en el conjunto  $newPop$ ); (c) la población general  $pop$  se actualiza mediante un reemplazo directo con elitismo, tomando las mejores soluciones de la élite  $S$  y del conjunto  $newPop$ . El tamaño máximo de  $S$  siempre es igual o menor que el tamaño de población principal (representado como  $popSize$ ).

#### IV. ESTUDIO EXPERIMENTAL

En esta sección, analizamos el rendimiento del algoritmo MIAR-GePro considerando una serie de conjuntos de datos y teniendo en cuenta hipótesis tradicional propuesta por Dietterich. En primer lugar, se realizará una comparativa del rendimiento de la propuesta respecto a un algoritmo de búsqueda exhaustivo (única propuesta existente en este campo hasta la fecha). En segundo lugar, se estudiarán una serie de métricas para medir la calidad media de las soluciones. Todos estos experimentos se realizarán considerando los siguientes parámetros en MIAR-GePro: 50 individuos; 100 generaciones; 0.8 probabilidad de cruce; 0.2 probabilidad de mutación; elitismo con un número máximo de soluciones de 20; y 0.1 como umbral de soporte mínimo.

En este estudio experimental se consideran 10 conjuntos de datos multi-instancia generados artificialmente (ver descripción en la Tabla I). A pesar de que existen multitud de conjuntos de datos reales multi-instancia en la literatura,

#### Algorithm 1 Pseudocódigo del algoritmo MIAR-GePro

---

**Require:**  $\Omega, popSize, maxGen, maxSol, \alpha, G$   
**Ensure:**  $S$

```

1:  $S \leftarrow \emptyset$ 
2:  $pop \leftarrow \emptyset$   $\triangleright$  Conjunto de soluciones de cada iteración
3:  $pop \leftarrow createSolutions(G, \Omega, popSize)$   $\triangleright$  Gramática  $G$  usada para generar soluciones
4:  $pop \leftarrow evaluationProcedure(\Omega, nExamples, pop, \alpha)$ 
5:  $S \leftarrow takeBestSolutions(pop, maxSol)$   $\triangleright$  Selecciona los  $maxSol$  mejores soluciones encontradas en  $pop$ 
6:  $generation \leftarrow 1$ 
7: while  $generation \leq maxGen$  do  $\triangleright$  El algoritmo itera un número específico de generaciones
8:    $parents \leftarrow selectParents(pop)$ 
9:    $newPop \leftarrow applyGeneticOperators(parents)$ 
10:   $newPop \leftarrow evaluationProcedure(\Omega, newPop, \alpha)$ 
11:   $S \leftarrow S \cup newPop$ 
12:   $pop \leftarrow takeBestSolutions(S, popSize)$   $\triangleright$  Selecciona las  $popSize$  mejores soluciones encontradas en  $S$ 
13:   $S \leftarrow takeBestSolutions(pop, maxSol)$   $\triangleright$  Selecciona las  $maxSol$  mejores soluciones encontradas en  $pop$ 
14:   $generation \leftarrow generation + 1$ 
15: end while
16: return  $S$ 

17: procedure EVALUATION PROCEDURE( $\Omega, pop, \alpha$ )
18:   $nExamples \leftarrow getNumberExamples(\Omega)$ 
19:  for all solutions  $s \in pop$  do  $\triangleright$  Soluciones en  $pop$ 
20:     $countS \leftarrow 0$   $\triangleright$  Ejemplos satisfechos por la regla
21:     $countA \leftarrow 0$   $\triangleright$  Ejemplos satisfechos por el antecedente
22:    for all examples  $e_i \in \Omega$  do
23:      for all instance  $t_{i,j} \in e_i$  do
24:        if  $s \subseteq t_{i,j}$  then
25:           $countS \leftarrow countS + 1$ 
26:        break
27:      end if
28:      if  $antecedent(s) \subseteq t_{i,j}$  then
29:         $countA \leftarrow countA + 1$ 
30:      break
31:      end if
32:    end for
33:    end for
34:     $support \leftarrow countS/nExamples$ 
35:     $supportA \leftarrow countA/nExamples$ 
36:     $confidence \leftarrow countS/countA$ 
37:    if  $support \geq \alpha$  then
38:       $assignFitness(s, support \times confidence)$ 
39:    else
40:       $assignFitness(s, 0)$ 
41:    end if
42:  end for
43: return  $pop$ 
44: end procedure

```

---

éstos han sido especialmente diseñados para tareas de clasificación y, por tanto, no proporcionan resultados interesantes para una tarea específica como ARM. Con el fin de poder ejecutar algoritmos de búsqueda exhaustiva como Apriori-MI, los conjuntos de datos que comprenden atributos numéricos se han discretizado previamente. No obstante, cabe destacar que MIAR-GePro se puede aplicar directamente tanto a atributos discretos como continuos, no requiriendo ningún paso previo de procesamiento de datos.



TABLE I  
CONJUNTO DE DATOS UTILIZADOS EN EL ESTUDIO EXPERIMENTAL

Conjunto de datos	#Ejemplos	#Atributos	#Instancias	Tamaño medio ejemplos
artificial1	200	6	705	3.53
artificial2	200	8	690	3.45
artificial3	500	8	1,742	3.48
artificial4	500	8	7,406	14.81
artificial5	1,000	10	6,958	6.96
artificial6	1,000	10	12,522	12.52
artificial7	2,000	12	19,986	9.99
artificial8	2,000	16	20,213	10.11
artificial9	5,000	6	17,482	3.50
artificial10	5,000	8	37,748	7.55

### A. Análisis del rendimiento

El análisis de la escalabilidad de MIAR-GePro con respecto al algoritmo Apriori-MI [5] se ha llevado a cabo por medio de dos formas diferentes (ver Figuras 2 y 3). En primer lugar, es importante destacar que la escalabilidad de los algoritmos de ARM ha sido ampliamente estudiada por diferentes investigadores [3], lo que demuestra que el tiempo de ejecución de los algoritmos de búsqueda exhaustiva aumenta exponencialmente con el número de atributos. En este estudio, queremos analizar el rendimiento de los algoritmos de búsqueda tanto evolutivos como exhaustivos cuando se aplican sobre conjuntos de datos multi-instancia, considerando diferentes números de ejemplos (Figura 2) y atributos (Figura 3). Como se muestra, el algoritmo Apriori-MI requiere un tiempo computacional más alto con el incremento del número de ejemplos (también conocidos como bolsas), obteniendo todas las posibles reglas de asociación que satisfacen los umbrales establecidos (valor mínimo de soporte de 0.1. Destacar que este valor tan bajo permite obtener casi todas las reglas de asociación existentes). En cuanto a la escalabilidad de los algoritmos para diferentes números de atributos (ver Figura 3), se obtiene que algoritmos de búsqueda exhaustivos como

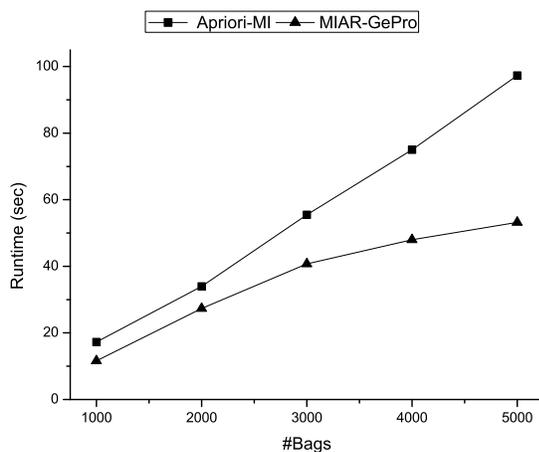


Fig. 2. Tiempo de ejecución en segundos para diferentes número de ejemplos (bolsas de instancias)

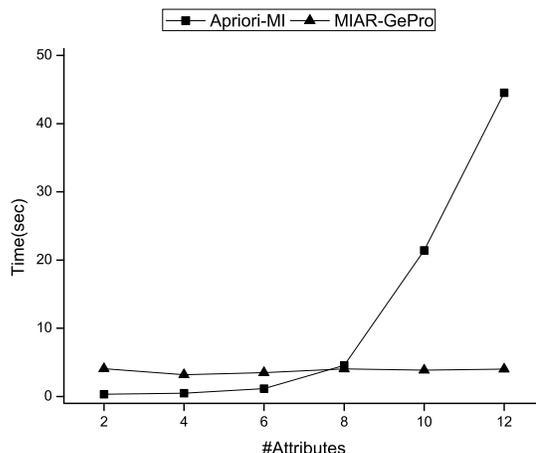


Fig. 3. Tiempo de ejecución en segundos para diferentes números de atributos

Apriori-MI aumentan exponencialmente su tiempo de cálculo con el incremento del número de atributos. Por el contrario, las propuestas evolutivas como MIAR-GePro no se ven afectadas por la cantidad de atributos.

### B. Análisis de las medidas de calidad

La tabla II muestra los resultados obtenidos para diez conjuntos de datos diferentes discretizados en 5, 10 y 15 intervalos de igual anchura (la discretización es un requisito previo para poder ejecutar el enfoque de búsqueda exhaustiva existente). El algoritmo Apriori-MI se ejecuta utilizando un Soporte mínimo de 0.1, por lo que el algoritmo no tiene en cuenta ninguna regla que tenga un valor de Soporte inferior y calcula tres medidas de calidad diferentes (Soporte, Confianza y Lift). Analizando los resultados promedio representados en la Tabla II, el número de reglas descubiertas es mayor cuando el número de intervalos en los que se discretiza es menor. Esto se debe a la mayor cantidad de ejemplos que podrían satisfacerse cuando los atributos están discretizados en un pequeño número de intervalos (mayor rango de valores). Por el contrario, el mero hecho de considerar un número mayor de valores discretos (rango inferior de valores) implica que los atributos o patrones apenas se satisfacen, por lo que el número de ejemplos que comprenden patrones específicos es menor.

El mismo análisis anterior se ha realizado utilizando un enfoque evolutivo (ver Tabla III). En este caso específico, MIAR-GePro no requiere discretizar los conjuntos de datos en un número de intervalos, por lo que MIAR-GePro se ejecuta utilizando únicamente un umbral de soporte mínimo de 0.1. Además, MIAR-GePro permite extraer un número específico de reglas, por lo que hay que indicar dicho número que será el de las mejores reglas encontradas (se fija en 20 debido a que es el número de reglas generalmente utilizadas por los expertos en ARM con enfoques evolutivos [3]). El análisis de los resultados para la métrica de Confianza en el algoritmo evolutivo (no requiere preprocesado) determina mejores resultados que Apriori-MI. Es bastante interesante cómo cuanto mayor es el número de intervalos, mejores son

TABLE II  
NÚMERO DE REGLAS OBTENIDAS Y VALORES MEDIOS PARA TRES MEDIDAS DE CALIDAD PARA EL ALGORITMO APRIORI-MI.

Conjunto de datos	#Reglas	Soporte	Confianza	Lift
artificial1-5	686	0.155	0.319	0.653
artificial1-10	192	0.156	0.408	1.101
artificial1-15	160	0.125	0.404	1.115
artificial2-5	1,480	0.147	0.324	0.702
artificial2-10	262	0.154	0.407	1.014
artificial2-15	208	0.128	0.406	1.112
artificial3-5	2,978	0.127	0.307	0.626
artificial3-10	140	0.240	0.548	0.994
artificial3-15	210	0.167	0.502	0.994
artificial4-5	36,788	0.147	0.244	0.365
artificial4-10	13,966	0.129	0.250	0.424
artificial4-15	430	0.313	0.560	0.987
artificial5-5	7,392	0.213	0.359	0.567
artificial5-10	294	0.294	0.542	0.993
artificial5-15	276	0.299	0.586	1.008
artificial6-5	26,670	0.172	0.263	0.372
artificial6-10	12,964	0.120	0.221	0.369
artificial6-15	538	0.289	0.538	0.998
artificial7-5	19,998	0.191	0.334	0.586
artificial7-10	35,979	0.118	0.342	0.993
artificial7-15	422	0.176	0.359	1.002
artificial8-5	15,523	0.164	0.366	0.898
artificial8-10	12,033	0.126	0.322	0.921
artificial8-15	528	0.194	0.542	1.001
artificial9-5	1,916	0.122	0.304	0.623
artificial9-10	100	0.243	0.552	1.002
artificial9-15	150	0.169	0.507	1.002
artificial10-5	4,498	0.226	0.372	0.581
artificial10-10	276	0.277	0.518	0.982
artificial10-15	224	0.309	0.592	1.024

TABLE III  
NÚMERO DE REGLAS Y VALORES MEDIOS PARA TRES MÉTRICAS DE CALIDAD OBTENIDOS CON MIAR-GePRO.

Conjunto de datos	#Reglas	Soporte	Confianza	Lift
artificial1	20	0.748	0.998	1.005
artificial2	20	0.895	1.000	1.005
artificial3	20	0.909	0.914	1.002
artificial4	20	0.975	0.999	0.999
artificial5	20	0.989	1.000	1.000
artificial6	20	0.987	0.999	0.999
artificial7	20	0.991	0.999	0.999
artificial8	20	0.995	1.000	1.000
artificial9	20	0.981	0.999	1.000
artificial10	20	0.997	0.999	0.999

los resultados obtenidos para esta medida de calidad en el enfoque de búsqueda exhaustiva. Esto explica por qué MIAR-GePro obtiene los mejores resultados, ya que no requiere un número fijo de intervalos (funciona directamente sobre atributos continuos).

## V. CONCLUSIONES

El creciente interés en el almacenamiento de datos ha causado no solo un crecimiento en la dimensionalidad de los datos, sino también en la variedad de sus representaciones. Estudios recientes han propuesto soluciones para extraer reglas de asociación en conjuntos de datos donde múltiples registros

describen un único objeto. Sin embargo, las soluciones existentes para la minería de reglas de asociación en este tipo de datos están restringidas a dominios discretos y requieren analizar todo el espacio de búsqueda (el tiempo de ejecución aumenta exponencialmente con el número de atributos). Así pues, el objetivo de este documento es proponer un nuevo algoritmo que permita trabajar en dominios continuos, obtener resultados lo antes posible y satisfacer las expectativas de los usuarios (los resultados deben coincidir con la forma deseada).

La propuesta MIAR-GePro utiliza programación genética gramatical para ARM sobre datos multi-instancia. MIAR-GePro puede trabajar en dominios discretos y continuos, representando una ventaja importante con respecto a la propuesta existente (Apriori-MI). Además, el modelo evolutivo propuesto es capaz de extraer las reglas de asociación en un solo paso (la propuesta existente requiere extraer primero todos los patrones frecuentes y, luego, obtener reglas de asociación de dichos patrones). El análisis experimental llevado a cabo en 10 diferentes conjuntos de datos ha demostrado que la propuesta es altamente eficiente, requiriendo un tiempo de ejecución que es casi constante para cualquier cantidad de atributos.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto TIN2017-83445-P del Ministerio de Economía y Competitividad y Fondos FEDER.

## REFERENCES

- [1] C. C. Aggarwal and J. Han, *Frequent Pattern Mining*. Springer International Publishing, 2014.
- [2] F. Padillo, J. M. Luna, F. Herrera, and S. Ventura, "Mining association rules on big data through mapreduce genetic programming," *Integrated Computer-Aided Engineering*, vol. 25, no. 1, pp. 31–48, 2018.
- [3] S. Ventura and J. M. Luna, *Pattern Mining with Evolutionary Algorithms*. Springer International Publishing, 2016.
- [4] T. G. Dietterich, R. H. Lathrop, and T. Lozano-Perez, "Solving the multiple instance problem with axis-parallel rectangles," *Artificial Intelligence*, vol. 89, no. 1–2, pp. 31 – 71, 1997.
- [5] J. M. Luna, A. Cano, V. Sakalauskas, and S. Ventura, "Discovering useful patterns from multiple instance data," *Information Sciences*, vol. 357, pp. 23–38, 2016.
- [6] F. Herrera, S. Ventura, R. Bello, C. Cornelis, A. Zafra, D. Sánchez Tarragó, and S. Vluymans, *Multiple Instance Learning - Foundations and Algorithms*. Springer, 2016. [Online]. Available: <https://doi.org/10.1007/978-3-319-47759-6>
- [7] N. Weidmann, E. Frank, and B. Pfahringer, "A Two-level Learning Method for Generalized Multi-instance Problems," in *Proceedings of the 14th European Conference on Machine Learning*, 2003, pp. 468–479.
- [8] R. Agrawal, T. Imielinski, and A. N. Swami, "Mining association rules between sets of items in large databases," in *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, ser. SIGMOD Conference '93, Washington, DC, USA, 1993, pp. 207–216.
- [9] J. Han, J. Pei, Y. Yin, and R. Mao, "Mining Frequent Patterns without Candidate Generation: A Frequent-Pattern Tree Approach," *Data Mining and Knowledge Discovery*, vol. 8, pp. 53–87, 2004.
- [10] F. Berzal, I. Blanco, D. Sánchez, and M. A. Vila, "Measuring the accuracy and interest of association rules: A new framework," *Intelligent Data Analysis*, vol. 6, no. 3, pp. 221–235, 2002.
- [11] R. McKay, N. Hoai, P. Whigham, Y. Shan, and M. O'Neill, "Grammar-based Genetic Programming: a Survey," *Genetic Programming and Evolvable Machines*, vol. 11, pp. 365–396, 2010.
- [12] P. Whigham and D. O. C. Science, "Grammatically-based genetic programming," in *Proceedings of the Workshop on Genetic Programming*, Tahoe City, California, USA, 1995, pp. 33–41.



# Aproximación al índice externo de validación de clustering basado en chi cuadrado

José María Luna-Romera, Jorge García-Gutiérrez, María Martínez-Ballesteros and José C. Riquelme Santos

Departamento de Lenguajes y Sistemas Informáticos

Universidad de Sevilla

Sevilla, España

**Abstract**—El clustering es una de las técnicas más utilizadas en minería de datos. Tiene como objetivo principal agrupar datos en clusters de manera que los objetos que pertenecen al mismo clúster sean más similares que los que pertenecen a diferentes clusters. La validación de un clustering es una tarea que se realiza aplicando los llamados índices de validación. Estos índices miden la calidad de la solución del clustering y se podrían clasificar como índices internos, los cuales calculan la calidad del clustering en función de los propios clusters; e índices externos, que miden la calidad mediante información externa de los datos, como puede ser la clase. Los índices externos que nos encontramos en la literatura están sujetos a una interpretación que puede dar lugar a error, por ello, el objetivo de este artículo es presentar un nuevo índice de validación externa basado en el test estadístico de chi cuadrado que mide la calidad del clustering de forma exacta, sin necesidad de tener que ser interpretado. Se ha realizado una experimentación usando 6 datasets que podrían ser considerados big data y los resultados obtenidos son prometedores ya que mejoran la tasa de aciertos y porcentaje de error respecto a los índices de la literatura.

**Index Terms**—Análisis de clustering, validación de clustering, índices de validación externa, Big Data

## I. INTRODUCCIÓN

El clustering es una técnica de minería de datos que agrupa datos no supervisados en clusters de manera que las instancias que pertenecen al mismo clúster son similares. El clustering se ha usado en diferentes áreas de conocimiento como las ciencias sociales [1], la biología [2], la electricidad [3] o la agricultura [4].

Existen numerosos métodos de clustering en la literatura, y por lo general, cada uno genera una solución de clustering diferente. En algunos casos, se pueden obtener diferentes soluciones con el mismo método con tan solo cambiar alguno de parámetros de entrada. Una de las principales tareas del clustering es el análisis y evaluación de las distintas soluciones. Para medir la calidad de la solución de clustering, existen los llamados índices de validación de clustering (CVI).

Los CVI se podrían dividir en dos categorías: índices internos e índices externos. Los índices internos miden la calidad de la solución en función de la distribución de las instancias por los clusters, es decir, evalúan la separación que existe entre los clusters y la compacidad que hay entre las instancias que pertenecen al mismo clúster. Este tipo de índice es el único que se puede aplicar cuando el dataset no aporta ningún dato adicional. Por otra parte, los índices externos son aquellos que evalúan los clusters en función de algún atributo

externo como puede ser la clase. Los índices de este tipo comparan el resultado del clustering con el de una solución global denominada *ground truth*. De esta forma los índices saben a priori la solución óptima así como el número óptimo de clusters del dataset ya que el *ground truth* contiene esta información. Por lo general, los índices de la literatura indican la solución óptima a través de una representación gráfica, y los resultados podrían ser interpretados de manera imprecisa. Los CVI se han usado en [5]–[8]. En este trabajo vamos a centrarnos en los índices de validación externos.

El objetivo de este artículo es presentar un nuevo CVI de clustering externo basado en el test estadístico de chi cuadrado cuyo resultado no necesite ser interpretado. La efectividad de este nuevo índice se ha comparado con 3 índices de la literatura en 6 datasets que podrían ser consideradas big data. La implementación del índice se ha realizado haciendo uso de las librerías MLlib de Spark [9] por lo que el índice estaría preparado para ejecutarse con datasets que podrían considerarse big data.

Este artículo se organiza de la siguiente forma: Sección II trata la literatura sobre los índices externos de validación. En la Sección III se introduce el nuevo índice propuesto en este trabajo. Sección IV presenta los experimentos, la metodología y los resultados obtenidos. Y por último, las conclusiones y trabajos futuros en la Sección V.

## II. TRABAJOS RELACIONADOS

Los índices externos evalúan los resultados de un clustering comparándolo con el *ground truth*. Los índices externos se podrían clasificar dependiendo del criterio de comparación del clustering con el *ground truth* [10]. Los índices podrían clasificarse en: *set matching*, *pair-counting* y *information theory*.

- *Set matching* es la categoría que establece que la etiqueta de cada instancia se corresponde con un clúster. Alguno de los índices de la literatura son *purity* [11], *F-measure* [12] y *Goodman-Kruskal* [13].
- Los índices *pair-counting* se basan en la comparación entre el número de instancias con la misma etiqueta y el resultado del clúster. Esta categoría incluye índices como: *rand index* [14], *adjusted rand index* [15], *Jaccard* [16], *Fowlkes-Mallows* [17], *Hubert Statistic* [18] y *Minkowski score* [19].

- Los índices basados en *information theory* como la *entropy* [11], *variation of information* [20] and *mutual information* [21] también se han aplicado en la literatura.

En los últimos años se han publicado en la literatura numerosos estudios que proponen nuevos índices externos para la validación de clusters. En [7] encontramos un nuevo índice *pair-counting* basado en un enfoque probabilístico intuitivo, que se utiliza para comparar soluciones que pueden tener un cierto grado de solape. Este índice fue probado usando 4 datasets artificiales con 6 clases y 4 datasets reales del repositorio UCI [22].

También se presentó un nuevo CVI en [23], pero en este caso, el índice se basa en la distancia Max-Min usando lo que denominan información previa. Este índice externo podría clasificarse en la categoría de *Set matching*. El rendimiento se comparó con índices de tipo *Set matching* y *Counting pairs* utilizando 6 datasets artificiales y 2 datasets reales también del repositorio UCI.

Los autores del trabajo presentado en [24] propusieron un nuevo índice basado en un conjunto de clasificadores supervisados. Podemos clasificar este índice como índice *pair-counting*. Para los experimentos se utilizaron 50 datasets reales del repositorio de la UCI y los resultados se compararon con algunos índices internos.

En [25] se presentó un nuevo CVI *pair-counting* para comparaciones analíticas. Aplica una corrección por azar y normaliza para cada grupo por separado. Los experimentos se llevaron a cabo con datasets artificiales con 3 clases y 6000 instancias cada una. Este nuevo índice obtuvo mejores resultados que otros CVI externos, tales como *purity*, *adjusted rand index* o *mutual information*.

Otros autores sugirieron en [26] un nuevo CVI de concordancia de texto basado en una concepción del grado de libertad que mide el intervalo de decisión entre dos clases. Este índice mide la calidad del clustering comparándolo con índices internos y externos. Se utilizaron 14 datasets reales para probar el rendimiento del índice.

La mayoría de estos CVI se comprueban comparando los resultados de los clusters con algunos de los CVI de la literatura y utilizando datasets sintéticos. Sin embargo, ninguno de estos índices ha sido probado en entornos paralelos y distribuidos utilizando grandes datasets. Este trabajo pretende proporcionar un CVI que permita trabajar con datasets que podrían considerarse big data y basado el test estadístico de chi cuadrado.

#### A. Chi cuadrado

El test estadístico de chi cuadrado es un método que mide la diferencia entre los valores esperados y los valores observados en una distribución entre dos variables [27]. La siguiente ecuación se utiliza para verificar esta correlación:

$$\chi^2 = \sum_i^r \sum_j^c \frac{(n_{ij} - E_{ij})^2}{E_{ij}} \quad (1)$$

donde  $r$  es el número de filas,  $c$  es el número de columnas,  $n_{ij}$  es el valor observado y  $E_{ij}$  es el valor esperado.  $E_{ij}$  viene dado por

$$E_{ij} = \frac{n_{ij}}{n} \quad (2)$$

donde  $n$  es el número total de instancias. De manera que el valor de  $\chi^2$  estará más cerca de cero cuanto más se asemeje el valor observado al valor esperado.

### III. ÍNDICE DE VALIDACIÓN DE CLUSTERING EXTERNO BASADO EN CHI CUADRADO

Supongamos una distribución de 12 instancias y 3 clases tal y como muestra la Figura 1, en la que cada punto representa una instancia y su color define la clase a la que pertenece.



Fig. 1: Representación de un dataset con 12 instancias y 3 clases donde los puntos representan a las instancias y los colores a las clases a las que pertenecen.

Antes de aplicar un método de clustering a este dataset tenemos que decidir el número de clusters ( $k$ ) en el que lo vamos a dividir. Nuestro objetivo es encontrar el número óptimo de clusters de manera que las instancias que pertenecen a la misma clase queden agrupadas en los mismos clusters, y que los clusters tengan mayoritariamente instancias de una sola clase. La Figura 2 muestra las soluciones de clustering con  $k = 2$  hasta  $k = 5$ , donde  $k$  es el número de clusters.

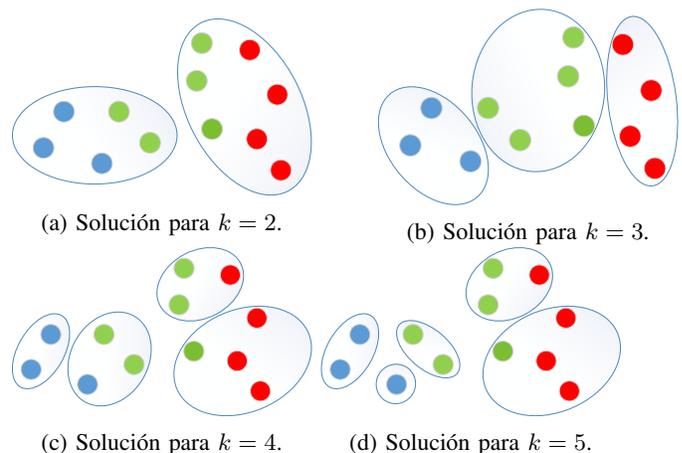


Fig. 2: Resultados de clustering para  $k = 2$  hasta  $k = 5$ .

Para medir objetivamente la calidad de cada solución de clustering necesitaríamos un índice de validación externo. El



denominado *chi index* mide la calidad del clustering basándose en el test estadístico de chi cuadrado. Chi index aplica el test estadístico a la tabla de contingencia generada por la solución de clustering. Una tabla de contingencia muestra la distribución de frecuencias de las instancias, teniendo en cuenta las clases, en forma de matriz.

Siguiendo el ejemplo de la Figura 1, la Tabla I presenta la tabla de contingencia para de la solución de clustering para  $k = 2$ . Aquí podemos ver que el clúster 1 tiene 3 instancias de la clase azul y 2 instancias verdes, mientras que el clúster 2 tiene 4 instancias rojas y 3 verdes. Esta tabla puede ser analizada desde dos puntos de vista diferentes, teniendo en cuenta que queremos que cada clúster tenga instancias de la misma clase y que las instancias de una misma clase queden agrupadas en mismos clusters:

- Si la analizamos por filas, podemos decir que el clúster 1 está compuesto solo por instancias azules y verdes, sin instancias rojas. Y el clúster 2 está formado por instancias rojas y verdes.
- Si analizamos la tabla por columnas, podemos concluir que las instancias azules están sólo en el clúster 1, las instancias rojas están sólo en el clúster 2, y las verdes están repartidas en ambos clusters.

TABLE I: Tabla de contingencia para la solución de clustering con  $k = 2$ .

Clúster	Azul	Rojo	Verde	Total
1	3	0	2	5
2	0	4	3	7
Total	3	4	5	12

Estas lecturas se representan en las Tablas II y IIB, que son las tablas de contingencia expresadas con las frecuencias relativas al total de filas (Tabla IIa) y de columnas (Tabla IIB).

TABLE II: Tablas de contingencia relativas para  $k = 2$ .

(a) Frecuencias relativas al total de cada fila.

Clúster	Azul	Rojo	Verde	Total
1	60%	0%	40%	100%
2	0%	57%	43%	100%

(b) Frecuencias relativas al total de cada columna.

Clúster	Azul	Rojo	Verde
1	100%	0%	40%
2	0%	100%	60%
Total	100%	100%	100%

El siguiente paso sería obtener el valor de chi cuadrado para estas tablas, y realizar el mismo procedimiento en cada iteración.

En este ejemplo de juguete, hemos calculado el índice de chi para las soluciones de clustering desde  $k = 2$  hasta  $k = 6$ . El objetivo es maximizar los valores del índice de chi en ambas tablas y minimizar la diferencia entre ellas. De esta manera, el

resultado del índice de chi intentará que los valores observados y esperados sean lo más diferentes posible. Esto obligará a mantener la solución con el porcentaje más alto de clases en cada grupo.

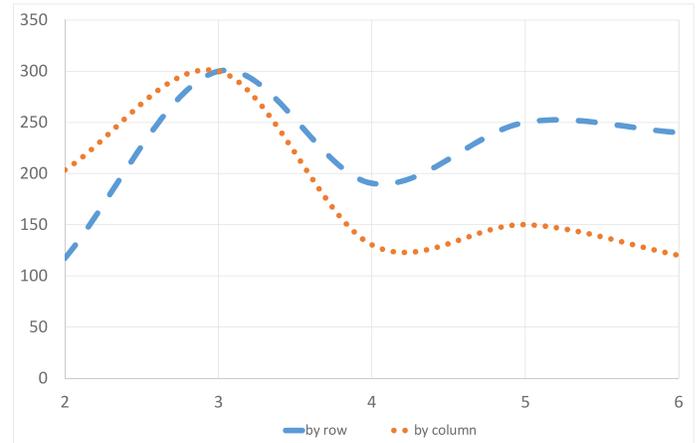


Fig. 3: Chi index result for  $k = 2$  to 6.

La figura 3 muestra los resultados de nuestro ejemplo de juguete desde  $k = 2$  hasta  $k = 6$ . Como se puede ver, en  $k = 3$  las curvas alcanzaron un máximo, y también ambas curvas tienen el mismo valor. Por lo tanto, la mejor solución de clustering para este conjunto de datos es  $k = 3$ . Cabe destacar que este índice señala la solución cuando ambas curvas están en la distancia mínima o cruzadas. La interpretación de la solución es bastante simple porque sólo hay que mirar donde se cruzan ambas curvas.

Las tablas III muestran las tablas de contingencia relativas para la solución  $k = 3$ . Como se puede observar, cada clúster solo tiene instancias de una misma clase (Tabla IIIa), y cada clase está distribuida en un mismo clúster (Tabla IIIb).

TABLE III: Tablas de contingencia relativas para la solución de clustering  $k = 3$ .

(a) Frecuencias relativas al total de cada fila.

Clúster	Azul	Rojo	Verde	Total
1	<b>100%</b>	0%	0%	100%
2	0%	0%	<b>100%</b>	100%
3	0%	<b>100%</b>	0%	100%

(b) Frecuencias relativas al total de cada columna.

Clúster	Azul	Rojo	Verde
1	<b>100%</b>	0%	0%
2	0%	0%	<b>100%</b>
3	0%	<b>100%</b>	0%
Total	100%	100%	100%

Por lo tanto, *chi index* podría definirse como:

$$chi\ index = \min(\chi_{fila}^2 - \chi_{columna}^2) \quad (3)$$

, donde

$$\chi_{fila}^2 = \sum_i^r \sum_j^c \frac{\left(\frac{n_{ij}}{n_i} - \frac{n_{ij}}{n}\right)}{\frac{n_{ij}}{n}} \quad (4)$$

$$\chi_{columna}^2 = \sum_i^r \sum_j^c \frac{\left(\frac{n_{ij}}{n_j} - \frac{n_{ij}}{n}\right)}{\frac{n_{ij}}{n}} \quad (5)$$

#### IV. RESULTADOS

Esta sección describe los experimentos llevados a cabo para testear el CVI propuesto. Para realizar la comparativa se han usado 6 datasets públicos que podrían considerarse big data y se han comparado los resultados con 3 CVI de la literatura. Esta sección se compone de la Sección IV-A donde se detallan los datasets que se han utilizado en los experimentos. La Sección IV-B presenta el diseño de los experimentos seguidos. La Sección IV-D muestra los resultados de los experimentos realizados. La sección IV-D1 incluye un análisis estadístico para probar la efectividad de nuestro índice propuesto para los conjuntos de datos públicos. Finalmente, se incluye una discusión sobre los resultados en la Sección IV-D2.

##### A. Datasets

La tabla IV muestra los datasets utilizados para los experimentos. La tabla muestra las siguientes características: el nombre del dataset, el número de clases que va a ser usado como el número óptimo de clusters, el número de características y el número de instancias. Todos estos conjuntos de datos fueron descargados del repositorio de machine learning de UCI [22]. Todos los datasets incluyen la etiqueta de la clase, pero ésta no se ha utilizado para el proceso de clustering, solo se ha usado en la etapa de análisis.

TABLE IV: Descripción de los datasets.

Datasets	Clases	Atributos	Instancias
airlines	2	7	539,383
convtype	7	54	581,012
higgs	2	28	11,000,000
kddcup99	2	41	494,020
poker	10	10	829,202
susy	2	12	5,000,000

##### B. Diseño de experimentos

Para generar las soluciones de clustering, se han aplicado 3 métodos de clustering de Spark incluidos en la librería MLlib [9]: k-means, bisecting k-means y Gaussian mixture.

Estos métodos de clustering necesitan el número de clusters ( $k$ ) en los que se va a particionar el dataset. Los experimentos se han realizado tomando los valores de  $k$  en el intervalo  $[D_k - 10, D_k + 10]$  donde  $D_k$  es el número correcto de clusters del dataset siendo  $k > 1$ . Cada dataset se ha ejecutado con cada uno de estos 3 métodos de clustering con los que se han obtenido un total de 360 soluciones de clustering para probar los CVI. La comparativa se ha realizado entre 3 CVI de la literatura descritos en la Sección II y nuestro *chi index* propuesto.

##### C. Efectividad del CVI

La efectividad se mide en función de la cercanía a una solución ya dada (*ground-truth*) y realizar una comparativa de los resultados. El primer paso consiste en aplicar el algoritmo de clustering al dataset y obtener las múltiples soluciones. En el segundo paso se evalúan las soluciones de clustering aplicando los CVI. En el tercer y último paso se comparan los resultados del CVI y se selecciona el que mejor puntuación haya obtenido siguiendo.

Para hacer una comparativa entre los diferentes CVI se van a tener en cuenta los siguientes valores:

- Media de aciertos: este valor viene dado por la media de veces que el índice acierta el número óptimo de clusters por el total de datasets.
- Error medio al cuadrado: se calcula como la media de las distancias entre la predicción del índice  $I_i$  y el número correcto  $n_i$  por el total de datasets:

$$Error = \frac{\sum_{i \in n} d(I_i, n_i)^2}{n} \quad (6)$$

, donde  $n$  es el número total de datasets.

1) *Test estadísticos*: Por último, se ha aplicado un marco estadístico para probar el rendimiento de los CVI. Se ha seleccionado el test no paramétrico de Quade y el procedimiento post-hoc de Holm para validar estadísticamente las diferencias en los rangos medios de los *p-values* correspondientes alcanzados. Este análisis estadístico se realizó utilizando la plataforma de código abierto StatService [28].

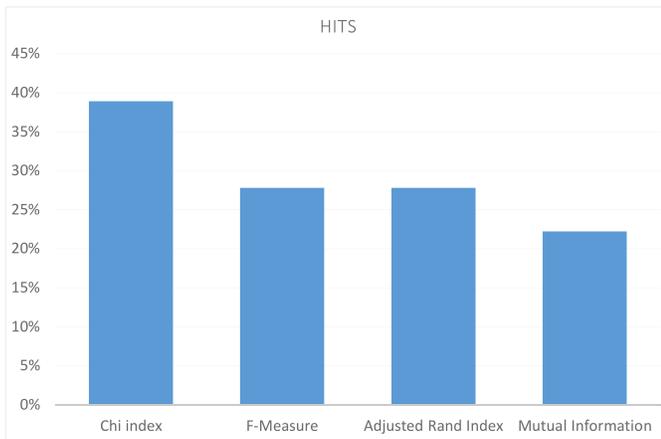
El test de Quade es una prueba estadística no paramétrica que evalúa las diferencias entre más de dos muestras estableciendo un ranking entre ellas. En nuestro caso, las muestras que vamos a evaluar son los CVI que vamos a comparar. Cuanto menor sea el *p-value*, mayor es la confianza de que un CVI funciona correctamente y, por lo tanto, se obtiene una mejor clasificación en el test de Quade.

Después de comprobar que los rankings medios son significativamente diferentes con un valor  $\alpha = 0,05$ , y siempre que el test de Quade rechaza la hipótesis nula, se realizará el test post-hoc de Holm para evaluar el rendimiento relativo de las CVI estudiadas frente a un índice de control, en nuestro caso, tomaremos el que obtenga mejor puntuación en el ranking de Quade.

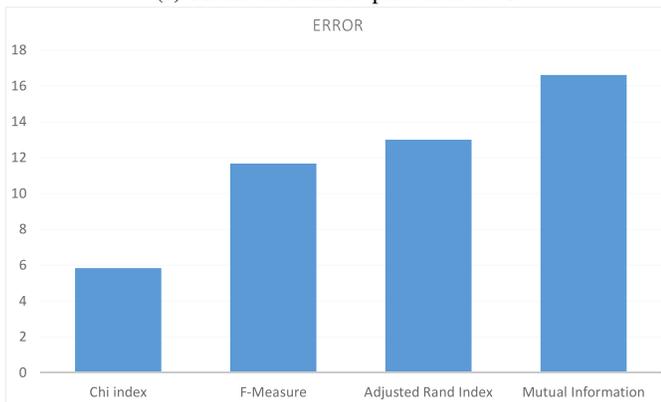
##### D. Resultados de los experimentos

Esta sección presenta los resultados realizados. La figura 4a muestra la media de aciertos para cada CVI en orden ascendente. *Chi index* ha alcanzado el valor más alto de aciertos (39%) con una diferencia significativa frente a sus competidores. Los índices de la literatura obtuvieron tasas similares de aciertos, que oscilaron entre el 28% en el caso de *F-Measure* y el 22% en el caso de *Mutual Information*.

Por otro lado, la Figura 4b presenta el error medio al cuadrado de cada CVI. Cabe señalar que *chi index* obtuvo el porcentaje de error más bajo (6%) quedando en segunda



(a) Media de aciertos para cada CVI.



(b) Error medio al cuadrado por CVI.

Fig. 4: Comparativa de resultados de los CVI.

posición *F-Measure* con casi el doble de puntos de error. Esto significa que *chi index* acierta el número óptimo de clusters la mayoría de las veces y en caso de error, el valor que indica no se aleja la solución.

1) *Análisis estadístico*: La Tabla V muestra el ranking del test de Quade para cada CVI. Como se muestra en el ranking, *chi index* ha quedado en primera posición con una puntuación de 1,807. El siguiente índice en el ranking fue *F-Measure* con una puntuación de 2,152, a 0,3 puntos del primer puesto. En última posición ha quedado *Mutual Information* con una puntuación en el ranking de 3,464.

TABLE V: Ranking del test de Quade.

CVI	Ranking
Chi index	1,807
F-Measure	2,152
Adjusted Rand Index	2,576
Mutual Information	3,464

El estadístico de Quade fue de 10,915, distribuida según una distribución F con 3 y 51 grados de libertad. El valor p de Quade fue 0,0 que fue inferior a 0,05. Por lo tanto, rechazó la hipótesis nula de que todos ellos se comportaron de manera similar con un nivel de significación de  $\alpha = 0,05$ .

Se ha realizado una prueba post-hoc por pares para verificar que nuestra propuesta es significativamente diferente al resto.

TABLE VI: Análisis post-hoc usando el procedimiento de Holm y tomando como índice de control a *chi index*.

CVI	p	z	$\alpha_{Holm}$
Mutual Information	0,0058	2,760	0,0167
Adjusted Rand Index	0,2003	1,280	0,025
F-Measure	0,5530	0,574	0,050

La tabla VI muestra los *p-values*, el valor z y  $\alpha_{Holm}$ , utilizando *chi index* como índice de control al ser el que mejor ranking obtuvo. Como puede verse, la hipótesis nula fue rechazada para todos los CVI. Por lo tanto, podemos concluir que *chi index* generó los mejores resultados (ya que obtuvo el mejor ranking) y fue estadísticamente diferente al resto de CVI.

2) *Discusión*: Los resultados del análisis de los datasets del repositorio de la UCI muestran que nuestro índice externo mejora la tasa de aciertos en 11% (Figura 4a). Además, en el caso de no poder alcanzar el número correcto de clusters, nuestro índice obtuvo una tasa de 6 puntos menos que los índices de la literatura (Figura 4b). Basado en la prueba de Quade (Tabla V), nuestro índice propuesto mejora los resultados en 2 puntos.

Es interesante resaltar que *chi index* indica la solución de clustering óptima de manera directa y concisa. A diferencia de los CVI de la literatura que necesitan ser interpretados siguiendo el método del codo y localizando máximos o mínimos locales, *chi index* indica la solución de clustering óptimo de manera directa y concisa como vimos en la Sección III.

## V. CONCLUSIONES

En este trabajo, se ha propuesto un nuevo índice de validación de clustering externo implementado en Spark para ser aplicado en datasets sin importar su tamaño. Hemos mostrado las diferencias entre nuestra propuesta y los índices de la literatura. El índice propuesto se basa en el test estadístico de chi cuadrado.

El estudio experimental indica que nuestro índice externo es muy competitivo. Hemos probado su efectividad en datasets públicos con un tamaño que podrían ser considerados big data en los que varían el número de clusters, sus características y el número de instancias. Los principales logros obtenidos son los siguientes:

- Un CVI externo basado en el test estadístico de chi cuadrado.
- Nuestro índice nos permitió estimar el número óptimo de clusters basado en la clase del dataset.
- Los resultados de *chi index* son directos y no requieren ser interpretados.
- El índice propuesto está listo para trabajar con conjuntos de datos que pueden ser considerados big data.
- El software de esta contribución se puede encontrar como un paquete de Spark en <http://spark-packages.org/package/josemarialuna/externalValidity>.

- El código fuente del índice de chi y los otros índices de la literatura se pueden encontrar en <https://github.com/josemarialuna/ExternalValidity>

Actualmente estamos aplicando este *chi index* en el análisis de datos de empleo y los resultados son prometedores. *Chi index* también se está aplicando en datos eléctricos en colaboración con una compañía eléctrica española. Como trabajo futuro, sería interesante ampliar la aplicación del índice en bases de datos que tengan multiclase.

#### AGRADECIMIENTOS

Este trabajo ha sido apoyado por el Ministerio de Economía y Competitividad bajo el proyecto TIN2014-55894-C2-R. J.M. Luna-Romera es becario FPI del Ministerio de Economía y Competitividad.

#### REFERENCES

- [1] M. Ghane'i-Ostad, H. Vahdat-Nejad, and M. Abdolrazzagh-Nezhad, "Detecting overlapping communities in lbnns by fuzzy subtractive clustering," *Social Network Analysis and Mining*, vol. 8, no. 1, 2018, cited By 0. [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85044313063&doi=10.1007%2fs13278-018-0502-5&partnerID=40&md5=96282433476a98b7bfc029f892772fc7>
- [2] F. Ginot, I. Theurkauff, F. Detcheverry, C. Ybert, and C. Cottin-Bizonne, "Aggregation-fragmentation and individual dynamics of active clusters," *Nature Communications*, vol. 9, no. 1, 2018, cited By 0. [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85042217142&doi=10.1038%2fs41467-017-02625-7&partnerID=40&md5=0d3b0fa19ff161e129139ac5de367f18>
- [3] R. Perez-Chacon, R. L. Talavera-Llames, F. Martinez-Alvarez, and A. Troncoso, "Finding electric energy consumption patterns in big time series data," in *Distributed Computing and Artificial Intelligence, 13th International Conference*, S. Omatu, A. Semalat, G. Bocewicz, P. Sitek, I. E. Nielsen, J. A. García García, and J. Bajo, Eds. Cham: Springer International Publishing, 2016, pp. 231–238.
- [4] X. Wu, J. Zhu, B. Wu, J. Sun, and C. Dai, "Discrimination of tea varieties using ftir spectroscopy and allied gustafson-kessel clustering," *Computers and Electronics in Agriculture*, vol. 147, pp. 64–69, 2018, cited By 0. [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85042208353&doi=10.1016%2fj.compag.2018.02.014&partnerID=40&md5=bbb11cb2c0d295517af2c497192a4d43>
- [5] J. Rojas-Thomas, M. Santos, and M. Mora, "New internal index for clustering validation based on graphs," *Expert Systems with Applications*, vol. 86, pp. 334 – 349, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417417304104>
- [6] J. Hämäläinen, S. Jauhainen, and T. Kärkkäinen, "Comparison of internal clustering validation indices for prototype-based clustering," *Algorithms*, vol. 10, no. 3, 2017, cited By 0. [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85029738018&doi=10.3390%2fa10030105&partnerID=40&md5=15f131f750705ed3aad57f2d3dbba8b1>
- [7] D. Campo, G. Stegmayer, and D. Milone, "A new index for clustering validation with overlapped clusters," *Expert Systems with Applications*, vol. 64, pp. 549 – 556, 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417416304158>
- [8] Z. Zhang, H. Fang, and H. Wang, "A new mi-based visualization aided validation index for mining big longitudinal web trial data," *IEEE Access*, vol. 4, pp. 2272–2280, 2016, cited By 7. [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84979828536&doi=10.1109%2fACCESS.2016.2569074&partnerID=40&md5=cb527399d9c0c9990be218434656d657>
- [9] A. Spark, "Clustering - Spark 2.2.0 Documentation," <https://spark.apache.org/docs/2.2.0/ml-clustering.html>, 2018, [Online; accessed 6-april-2018].
- [10] M. Rezaei and P. Fränti, "Set matching measures for external cluster validity," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 8, pp. 2173–2186, Aug 2016.
- [11] Y. Zhao and G. Karypis, "Criterion functions for document clustering: Experiments and analysis," *Tech. Rep.*, 2002.
- [12] B. Larsen and C. Aone, "Fast and effective text mining using linear-time document clustering," in *Proceedings of the Fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ser. KDD '99. New York, NY, USA: ACM, 1999, pp. 16–22. [Online]. Available: <http://doi.acm.org/10.1145/312129.312186>
- [13] L. A. Goodman and W. H. Kruskal, *Measures of Association for Cross Classifications*. New York, NY: Springer New York, 1979, pp. 2–34. [Online]. Available: [https://doi.org/10.1007/978-1-4612-9995-0\\_1](https://doi.org/10.1007/978-1-4612-9995-0_1)
- [14] W. M. Rand, "Objective criteria for the evaluation of clustering methods," *Journal of the American Statistical Association*, vol. 66, no. 336, pp. 846–850, 1971. [Online]. Available: <http://www.jstor.org/stable/2284239>
- [15] N. X. Vinh, J. Epps, and J. Bailey, "Information theoretic measures for clusterings comparison: Is a correction for chance necessary?" in *Proceedings of the 26th Annual International Conference on Machine Learning*, ser. ICML '09. New York, NY, USA: ACM, 2009, pp. 1073–1080. [Online]. Available: <http://doi.acm.org/10.1145/1553374.1553511>
- [16] R. Sokal and P. Sneath, *Principles of Numerical Taxonomy*, ser. Books in biology. W. H. Freeman, 1963. [Online]. Available: <https://books.google.es/books?id=3Y4aAAAAMAAJ>
- [17] E. B. Fowlkes and C. L. Mallows, "A method for comparing two hierarchical clusterings," *Journal of the American Statistical Association*, vol. 78, no. 383, pp. 553–569, 1983.
- [18] L. Hubert and P. Arabie, "Comparing partitions," *Journal of Classification*, vol. 2, no. 1, pp. 193–218, Dec 1985. [Online]. Available: <https://doi.org/10.1007/BF01908075>
- [19] A. Ben-Hur and I. Guyon, *Detecting Stable Clusters Using Principal Component Analysis*. Totowa, NJ: Humana Press, 2003, pp. 159–182. [Online]. Available: <https://doi.org/10.1385/1-59259-364-X:159>
- [20] M. Meilă, "Comparing clusterings by the variation of information," in *Learning Theory and Kernel Machines*, B. Schölkopf and M. K. Warmuth, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003, pp. 173–187.
- [21] A. Banerjee, I. S. Dhillon, J. Ghosh, and S. Sra, "Clustering on the unit hypersphere using von mises-fisher distributions," *J. Mach. Learn. Res.*, vol. 6, pp. 1345–1382, Dec. 2005. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1046920.1088718>
- [22] D. Dheeru and E. Karra Taniskidou, "UCI machine learning repository," 2017. [Online]. Available: <http://archive.ics.uci.edu/ml>
- [23] A. Alok, S. Saha, and A. Ekbal, "Development of an external cluster validity index using probabilistic approach and min-max distance," vol. 6, pp. 494–504, 06 2012.
- [24] J. Rodríguez, M. Medina-Pérez, A. Gutierrez-Rodríguez, R. Monroy, and H. Terashima-Marín, "Cluster validation using an ensemble of supervised classifiers," *Knowledge-Based Systems*, vol. 145, pp. 1–14, 2018.
- [25] M. Rezaei and P. Fränti, "Set matching measures for external cluster validity," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 8, pp. 2173–2186, Aug 2016.
- [26] C. Liu, W. Wang, M. Konan, S. Wang, L. Huang, Y. Tang, and X. Zhang, "A new validity index of feature subset for evaluating the dimensionality reduction algorithms," *Knowledge-Based Systems*, vol. 121, pp. 83 – 98, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S095705117300291>
- [27] J. Antoch, "A Guide to Chi-Squared Testing : Greenwood, P.E. and Nikulin, M.S. New York: John Wiley & Sons, Inc., pp. 280 +XII, ISBN 0-471-55779-X. AMS 1991 Classification: 62-02, 62F03, 62H15," *Computational Statistics & Data Analysis*, vol. 23, no. 4, pp. 565–566, February 1997. [Online]. Available: <https://ideas.repec.org/a/eee/csdana/v23y1997i4p565-566.html>
- [28] J. A. Parejo, J. García, A. Ruiz-Cortés, and J. C. Riquelme, "StatService: Herramienta de análisis estadístico como soporte para la investigación con metaheurísticas," in *Actas del VIII Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bio-Inspirados*, 2012.



# Atipicidad: Medida de calidad clave dentro del descubrimiento de reglas descriptivas supervisadas

C.J. Carmona<sup>1</sup>, M.J. del Jesus<sup>1</sup>, F. Herrera<sup>2</sup>

<sup>1</sup>Departamento de Informática. Universidad de Jaén, España ccarmona@ujaen.es, mjjesus@ujaen.es

<sup>2</sup>Departamento de Ciencias de la Computación e Inteligencia Artificial. Universidad de Granada, España herrera@decsai.ugr.es

<sup>1,2</sup>Instituto Data Science and Computational Intelligence (DaSCI)

**Resumen**—Esto es un resumen de nuestro trabajo publicado en la revista *Knowledge-Based Systems* [1] para su presentación en la Multiconferencia CAEPIA'18 Key Works.

**Index Terms**—Descubrimiento de reglas descriptivas supervisadas, Descubrimiento de subgrupos, Conjuntos de contraste, Patrones emergentes, Atipicidad.

## I. RESUMEN

A lo largo de la literatura podemos encontrar un conjunto de técnicas que se encuentran a medio camino entre la predicción y la descripción, agrupadas bajo el nombre de descubrimiento de reglas descriptivas bajo aprendizaje supervisado (SDRD) [1], [2]. Este conjunto de técnicas intenta obtener reglas de una categoría o clase prefijada para describir información significativa y relevante del conjunto de datos.

El principal objetivo de las técnicas dentro de SDRD no es extraer un modelo para clasificar nuevas instancias, sino obtener un modelo que permita comprender, describir o encontrar fenómenos subyacentes de interés en los datos. Dentro de este área de investigación se agrupan todas aquellas técnicas que, mediante el uso de reglas y un modelo de aprendizaje supervisado, intentan obtener conocimiento descriptivo de los datos que sea significativo, inusual y de interés para el usuario, como el descubrimiento de subgrupos [3], la minería de patrones emergentes [4] y los conjuntos de contraste [5], entre otros. A continuación se describen brevemente estas técnicas.

**Descubrimiento de subgrupos:** Se define como el descubrimiento de subgrupos de la población estadísticamente interesantes, esto es, tan grandes como sea posible y con una distribución estadística de la propiedad de interés lo más atípica posible respecto al conjunto de la población. La medida de calidad para medir esta atipicidad [6] en una regla  $R$  se define como:

$$WRAcc(R) = \frac{p+n}{P+N} \left( \frac{p}{p+n} - \frac{P}{P+N} \right) \quad (1)$$

**Conjuntos de contraste:** Es una técnica de exploración para contrastar diferencias de grupos dentro de un conjunto de datos, es decir, descubrir conjuntos de ejemplos con amplias diferencias de soporte entre grupos del conjunto de datos y se mide mediante la diferencia de soporte [5]:

$$DS(R) = \left| \frac{p}{P} - \frac{n}{N} \right| \geq \delta \quad (2)$$

**Patrones emergentes:** Se centra en buscar conocimiento relacionado con los valores de una clase, donde el número de instancias cubiertas por un patrón sea muy elevado para un valor de la variable objetivo y muy bajo o nulo para el resto; es decir, que el mismo patrón tenga un soporte muy alto para una clase y muy bajo para las demás clases del problema, y viene dado por el índice de crecimiento [4] que se representa a continuación:

$$GR(R) = \frac{\frac{p}{n}}{\frac{P}{N}} > 1 \quad (3)$$

Centrándonos en la importancia de la medida de atipicidad hay que destacar que mide el equilibrio entre generalidad y precisión. En concreto, el segundo factor de la atipicidad es el factor que mide la ganancia de precisión, y tal y como se puede observar, es posible que la atipicidad de una regla sea inferior a cero cuando la regla tiene una baja calidad ya que el porcentaje de ejemplos negativos cubiertos es superior al de los positivos. En este sentido, una regla de interés para el experto debería tener siempre un valor positivo, es decir, se debe cumplir la siguiente desigualdad para obtener una regla de interés:

$$\frac{p}{p+n} > \frac{P}{P+N} \quad (4)$$

Si descomponemos esta desigualdad [1] podemos decir que para que una regla obtenga una atipicidad positiva y ser un subgrupo de interés, obtenemos que el producto escalar entre  $p\bar{n}$  debe ser superior que  $\bar{p}n$ . En consecuencia, esta descomposición nos indica que el producto de ejemplos cubiertos y no cubiertos correctamente debería ser superior al producto de ejemplos cubiertos y no cubiertos incorrectamente:

$$p\bar{n} > \bar{p}n \quad (5)$$

En el trabajo publicado en [1] se presenta tras este primer análisis, la compatibilidad entre el descubrimiento de subgrupos, los conjuntos de contraste y los patrones emergentes gracias al uso de esta medida de calidad.

Por ejemplo, en el caso de los patrones emergentes (según definición) podemos afirmar que una regla es emergente cuando su índice de crecimiento es superior a 1, es decir:

$$GR(R) = \frac{\frac{p}{\bar{p}}}{\frac{N}{\bar{N}}} > 1 \quad (6)$$

Si aplicamos una descomposición a esta formulación descubrimos que:

$$\frac{\frac{p}{\bar{p}}}{\frac{N}{\bar{N}}} > 1 \quad (7)$$

$$p \bar{n} > \bar{p} n$$

Según esta demostración podemos afirmar que la descomposición de la atipicidad positiva y del índice de crecimiento son similares, es decir, si un subgrupo es de interés también es un patrón emergente. Además, por otro lado se puede observar una relación directa entre la atipicidad y la diferencia de soporte en [2] que dice:

$$DS(R) = \frac{WRAcc(R)}{p(PIS) \cdot p(NIS)} \geq \delta \quad (8)$$

donde  $p(PIS)$  es el porcentaje de ejemplos positivos para la clase del conjunto de datos a analizar y  $p(NIS)$  es el porcentaje de ejemplos negativos para el conjunto de datos.

Al mismo tiempo, es importante tener en cuenta que el dominio de la atipicidad para un problema depende del porcentaje de los ejemplos para la clase o variable objetivo [7], y por tanto, el dominio se puede determinar mediante las siguientes ecuaciones para el límite inferior ( $LB_{WRAcc}$ ) y para el superior ( $UB_{WRAcc}$ ):

$$LB_{WRAcc} = (1 - p(PIS)) \cdot (0 - p(PIS)) \quad (9)$$

$$UB_{WRAcc} = p(PIS) \cdot (1 - p(PIS)) = p(PIS) \cdot p(NIS) \quad (10)$$

Es decir, el valor de  $DS$  depende de las propiedades del problema ya que está directamente relacionado con el porcentaje de ejemplos de la clase a analizar, y en resumen:

$$DS(R) = \frac{WRAcc(R)}{p(PIS) \cdot p(NIS)} = \frac{WRAcc(R)}{UB_{WRAcc}} \geq \delta \quad (11)$$

Una regla se considera conjunto de contraste con un  $\delta = 0,10$  cuando:

$$WRAcc(R) \geq 0,10 \cdot UB_{WRAcc} \quad (12)$$

Sin embargo, tenemos la necesidad de estandarizar este valor de  $WRAcc$  a  $WRAcc$  normalizada ( $WRAccN$ ) ya que debemos evitar la utilización de un valor  $\delta$  que esté condicionado a este porcentaje de ejemplos de la clase a analizar. Esta mejora se consigue con respecto a la homogeneización de esta medida clave dentro del descubrimiento de reglas descriptivas supervisadas. La  $WRAccN$  se normaliza en el intervalo  $[0,1]$  mediante la siguiente ecuación donde una regla es subgrupo de interés cuando su valor sea superior a 0.5.

$$WRAccN(R) = \frac{WRAcc(R) - LB_{WRAcc}}{UB_{WRAcc} - LB_{WRAcc}} \quad (13)$$

Considerando un  $\delta$  igual a 0.10, y el intervalo positivo de  $WRAccN$  igual a  $(0.5, 1.0]$ , una regla se considera conjunto de contraste con un  $\delta = 0,10$  cuando:

$$WRAccN(R) \geq 0,50 + 0,10 \cdot (1,00 - 0,50) \quad (14)$$

$$WRAccN(R) \geq 0,55$$

, es decir, cuando el valor de la  $WRAccN$  es superior o igual que el 10 % de la parte positiva de  $WRAcc$ .

En conclusión, la atipicidad es un factor clave a medir dentro del descubrimiento de reglas descriptivas supervisadas donde una regla con un valor de  $WRAccN$  superior a 0.50 se considera de interés para el descubrimiento de subgrupos, y emergente para la extracción de patrones emergentes. Además, si la  $WRAccN$  es superior o igual a 0.55 se considera también regla de contraste. Esta demostración muestra la relación directa entre todas estas técnicas que se han agrupado dentro del descubrimiento de reglas descriptivas supervisadas y muestra la importancia de medir la calidad de una regla con respecto a la  $WRAcc$  en un problema que se desea analizar. Por otro lado, es interesante indicar que solo con el análisis de esta medida de calidad, los expertos serán capaces de determinar si la regla representa un subgrupo, una regla emergente y/o una regla de contraste. De la misma forma, esta medida debe ser clave para el diseño de nuevas propuestas dentro del descubrimiento de reglas descriptivas supervisadas.

#### AGRADECIMIENTOS

Este trabajo ha sido subvencionado por el Ministerio de Economía y Competitividad de España bajo el proyecto TIN2014-916 57251-P y TIN2015-68454-R (Fondos FEDER).

#### REFERENCIAS

- [1] C. J. Carmona, M. J. del Jesus, and F. Herrera, "A Unifying Analysis for the Supervised Descriptive Rule Discovery via the Weighted Relative Accuracy," *Knowledge-Based Systems*, vol. 139, pp. 89–100, 2018.
- [2] P. Kralj-Novak, N. Lavrac, and G. I. Webb, "Supervised Descriptive Rule Discovery: A Unifying Survey of Constrain Set, Emerging Pattern and Subgroup Mining," *Journal of Machine Learning Research*, vol. 10, pp. 377–403, 2009.
- [3] W. Kloesgen, "Explora: A Multipattern and Multistrategy Discovery Assistant," in *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence, 1996, pp. 249–271.
- [4] G. Z. Dong and J. Y. Li, "Efficient Mining of Emerging Patterns: Discovering Trends and Differences," in *Proc. of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM Press, 1999, pp. 43–52.
- [5] S. D. Bay and M. J. Pazzani, "Detecting group differences: Mining contrast sets," *Data Mining and Knowledge Discovery*, vol. 5, no. 3, pp. 213–246, 2001.
- [6] N. Lavrac, P. A. Flach, and B. Zupan, "Rule Evaluation Measures: A Unifying View," in *Proc. of the 9th International Workshop on Inductive Logic Programming*, ser. LNCS, vol. 1634. Springer, 1999, pp. 174–185.
- [7] C. J. Carmona, V. Ruiz-Rodado, M. J. del Jesus, A. Weber, M. Grootveld, P. González, and D. Elizondo, "A fuzzy genetic programming-based algorithm for subgroup discovery and the application to one problem of pathogenesis of acute sore throat conditions in humans," *Information Sciences*, vol. 298, pp. 180–197, 2015.

**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 3:  
APLICACIONES







# Modeling the navigation on enrolment web information area of a university using machine learning techniques\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Ainhoa Yera, Iñigo Perona, Olatz Arbelaitz, Javier Muguerza  
*Faculty of Informatics*  
*University of the Basque Country*  
Donostia, Spain  
{ainhoa.yera, inigo.perona, olatz.arbelaitz, j.muguerza}@ehu.eus

**Abstract**—This work analyses the navigation in the enrolment web information area of the University of the Basque Country. A complete data mining process shows that successful and failure navigation behaviors can be modeled using machine learning techniques. Unsupervised learning algorithms have been applied on two different domains: URLs visited by the users in each session (navigation sequence) and some interaction parameters extracted from the recorded click-stream (navigation style). Both domains have been used satisfactorily to model the behavior of success and failure navigation sessions achieving more than 78 % of accuracy predicting success or failure sessions. Furthermore, the clustering based on the navigation style was able to identify the main characteristics of each type of session and to build a subsystem that enables to detect failure type sessions with high precision.

**Index Terms**—Web Usage Mining, Navigation Models, Web Interaction Characterization



# Risk factors for development of antibiotic resistance of *Enterococcus faecium* to Vancomycin. A subgroup discovery approach\*

\*Note: The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

A. Fajfar

Faculty of Health Sciences  
University of Maribor  
Maribor, Slovenia

M. Campos

Faculty of Computer Science  
University of Murcia  
Murcia, Spain  
manuelcampos@um.es

F. Palacios

University Hospital of Getafe  
Madrid, Spain

B. Canovas-Segura

Faculty of Computer Science  
University of Murcia  
Murcia, Spain

G. Stiglic

Faculty of Health Sciences  
University of Maribor  
Maribor, Slovenia

R. Marin

Faculty of Computer Science  
University of Murcia  
Murcia, Spain

**Abstract**—Health-care associated infections (HAI) are infections that are not present or incubated at the time of admission to hospital. HAI are one of the major causes of morbidity and mortality among immunocompromised patients and have an important economic impact. The bacteria isolated in microbiology cultures can be treated with a limited combination of antibiotics owing to their resistance to many groups of antibiotics, which represents a major challenge. This paper focuses on the problem of vancomycin resistant *Enterococcus faecium* (VREfm) due to its high prevalence in HAI, multidrug resistance and ability to survive under intense selective pressure. We use the subgroup discovery technique to identify target populations with high risk clinical factors for VREfm infections that we shall be able to incorporate into a clinical decision support system for antimicrobial stewardship program. The dataset used contained 201 susceptibility tests with *Enterococcus faecium* from a University Hospital in years 2014 and 2015. The clinician evaluated and discussed the knowledge reported by the most interesting subgroups based on their positive predictive value and sensitivity.

**Index Terms**—



# Algoritmos de aprendizaje automático para predicción de niveles de niebla usando ventanas estáticas y dinámicas.

M. Díaz-Lozano<sup>a</sup>, D. Guijo-Rubio<sup>a</sup>, P. A. Gutiérrez<sup>a</sup>, C. Casanova-Mateo<sup>b,c</sup>, S. Salcedo-Sanz<sup>d</sup>,  
C. Hervás-Martínez<sup>a</sup>

**Resumen**—Los eventos de muy baja visibilidad producidos por niebla son un problema recurrente en ciertas zonas cercanas a ríos y grandes montañas, que afectan fuertemente a la actividad humana en diferentes aspectos. Este tipo de eventos pueden llegar a suponer costes materiales e incluso humanos muy importantes. Uno de los sectores más influenciados por las condiciones de muy baja visibilidad son los medios de transporte, fundamentalmente el transporte aéreo, cuya actividad se ve seriamente mermada, provocando retrasos, cancelaciones y, en el peor de los casos, terribles accidentes. En el aeropuerto de Valladolid son muy frecuentes las situaciones de baja visibilidad por niebla, especialmente en los meses considerados de invierno (noviembre, diciembre, enero y febrero). Esto afecta de forma directa a la manera en la que operan los vuelos de este aeropuerto. De esta forma, es muy importante conocer las posibles condiciones de niebla a corto plazo para aplicar procedimientos de seguridad y organización dentro del aeropuerto. En el presente artículo se propone el uso de diferentes modelos de ventanas dinámicas y estáticas junto con clasificadores de aprendizaje automático, para la predicción de niveles de niebla. En lugar de abordar el problema como una tarea de regresión, la variable de interés para la caracterización del nivel de visibilidad en el aeropuerto (Rango Visual de Pista, RVR) se discretiza en 3 categorías, lo que aporta mayor robustez a los modelos de clasificación obtenidos. Los resultados indican que una combinación de ventana dinámica con ventana estática, junto con modelos de clasificación basados en *Gradient Boosted Trees* es la metodología que proporciona los mejores resultados.

**Palabras clave**—Series temporales, Eventos de baja visibilidad, modelos autorregresivos, predicción.

## I. INTRODUCCIÓN

La niebla es un fenómeno meteorológico que consiste en la aparición de gotas de agua en suspensión en forma de gotas, lo

<sup>a</sup>: Dpto. de Informática y Análisis Numérico, Universidad de Córdoba, Córdoba, España. E-mail: {i42dilom, dguijo, pagutierrez, chervas}@uco.es

<sup>b</sup>: LATUV: Laboratorio de Teledetección, Universidad de Valladolid, Valladolid, España.

<sup>c</sup>: Dpto. de Ingeniería Civil: Construcción, Infraestructura y Transporte, Universidad Politécnica de Madrid, Madrid, España.

<sup>d</sup>: Dpto. de Teoría de la Señal y Comunicaciones, Universidad de Alcalá, Alcalá de Henares, Madrid, España. E-mail: sancho.salcedo@uah.es

Este trabajo ha sido desarrollado con la financiación de los proyectos TIN2017-85887-C2-1-P, TIN2017-85887-C2-2-P y TIN2017-90567-REDT del Ministerio de Economía y Competitividad de España (MINECO) y fondos FEDER. La investigación de David Guijo Rubio ha sido subvencionada por el proyecto PI15/01570 de la Fundación de Investigación Biomédica (FIBICO) y por el Programa Predoctoral FPU (Ministerio de Educación y Ciencia de España), referencia de beca FPU16/02128.

suficientemente pequeñas como para que la gravedad terrestre no las atraiga hacia la superficie. Este fenómeno se manifiesta a nivel de suelo, pudiendo considerarse una nube a muy baja altura. Su aparición puede deberse a diferentes causas, como la evaporación de la humedad del suelo o a la expedición de vapor por parte de vegetación o de grandes masas de agua [1]. En cualquier caso, su aparición está íntimamente ligada a la disminución de las condiciones de visibilidad en la superficie. Estos eventos de baja visibilidad suponen un riesgo particular para el tráfico aéreo, marítimo y terrestre, provocando interrupciones y problemas cuyos costes humanos se han llegado a comparar a los causados por tormentas y tornados [2]. En las operaciones llevadas a cabo en los aeropuertos, el tráfico de vuelos se ve fuertemente afectado en estas condiciones [3], [4], debiendo ampliar el tiempo entre aterrizajes y despegues y pudiendo provocar retrasos y cancelaciones. Por esta razón, el personal de los aeropuertos necesita conocer con cierta precisión y antelación si en un futuro cercano tendrán que trabajar con condiciones de baja visibilidad por niebla, para activar los protocolos necesarios en su caso, y tratar de mitigar este tipo de situaciones problemáticas.

La predicción de eventos futuros tiene interés en la mayoría de campos de estudio, creándose multitud de modelos destinados para este cometido [5], [6], aplicados con éxito a problemas de predicción reales. Todos estos modelos suelen estar basados en análisis de series temporales, normalmente sobre codificación real. Los eventos de niebla que provocan baja visibilidad son un problema recurrente en multitud de aeropuertos en todo el mundo, y su predicción se ha enfocado mediante diversas técnicas: en Perth, el aeropuerto más grande de la costa sudoeste de Australia, se desarrolló un modelo que aplicaba lógica difusa para conseguir una predicción precisa [7]; en el aeropuerto de Calcuta, India, se abordó el problema utilizando árboles de decisión para identificar los parámetros más importantes que influyen en la visibilidad, realizando predicciones mediante una red neuronal [8]; en el aeropuerto de Valladolid, situado al noroeste de España, se afrontó este problema haciendo uso de diversos algoritmos de aprendizaje automático para regresión como máquinas de vectores soporte, preprocesando la serie antes de aplicarlos [9].

El objetivo de este artículo es proponer un modelo de

predicción horario basado en el preprocesamiento de series temporales categóricas, donde los eventos temporales son tres diferentes condiciones atmosféricas relacionadas con la aparición de eventos de baja visibilidad por niebla: no-niebla, neblina y niebla. Este preprocesamiento se lleva a cabo mediante el uso de diversos tipos de ventanas de valores pasados de las series temporales consideradas, de forma que la información obtenida a partir de cada serie pueda ser usada en el entrenamiento de cualquier modelo de aprendizaje automático.

En la siguiente sección (sección II), se presenta la base de datos considerada. En la sección III, se detallan los modelos de ventana propuestos para preprocesar los datos y para realizar las predicciones. En la sección IV, se detalla la configuración de la experimentación y los resultados obtenidos. Por último, la sección V incluye las conclusiones obtenidas a partir de los resultados conseguidos.

## II. BASE DE DATOS

### II-A. Origen de los datos

Los datos utilizados en este artículo han sido recopilados mediante un sistema localizado en el aeropuerto de Valladolid y perteneciente a la Agencia Estatal de Meteorología Española (AEMET). Dicho sistema provee información relevante sobre las condiciones meteorológicas al personal de los aeropuertos (pilotos, controladores y personal de tierra). De forma horaria, el sistema recoge información sobre diferentes factores meteorológicos, tales como la temperatura o la humedad. Dichos datos son recogidos por sensores y, por tanto, no existen datos perdidos, pudiéndose considerar cada variable meteorológica obtenida como una serie temporal. Las variables recogidas por este sistema son las siguientes: Temperatura (grados Celsius), Humedad relativa (%), Velocidad del viento (m/s), Dirección del viento (grados), Presión reducida al nivel del mar (QNH, hPa) y Rango Visual de Pista (*Runaway Visual Range, RVR*), que es la variable objetivo a predecir y se mide en metros.

El RVR se obtiene a partir de la media ponderada de tres sensores de visibilidad (visibilímetros), colocados a diferentes alturas de la pista (zona de toma de tierra, media pista y zona de parada). Además, las condiciones de niebla pueden modelarse mediante la combinación del resto de variables meteorológicas medidas, por estar ambas intrínsecamente relacionadas. Los experimentos llevados a cabo en este artículo se han realizado con datos horarios de 8 años completos, concretamente desde el 1 de noviembre de 2009 hasta el 31 de diciembre de 2016. De la totalidad de datos, el 70% inicial ha sido usado para la fase de entrenamiento y el último 30% para la fase de generalización.

### II-B. Umbralización del RVR

Los visibilímetros utilizados en el aeropuerto de Valladolid solo obtienen medida hasta 2000m, considerando situaciones de visibilidad óptima por encima de esta medida (es decir marcan 2000m incluso cuando el valor real de visibilidad es más alto). Esto es debido a que los valores de visibilidad por encima de 2000m son considerados óptimos, y por tanto

no son relevantes para la gestión de situaciones de baja visibilidad en el aeropuerto. En la experimentación diseñada en este artículo se propone un enfoque de predicción categórico mediante 3 clases, en el que a cada hora se le asigna una de las 3 posibles clases (alta, media o baja en relación al valor de RVR, asociado a las condiciones de niebla). Los umbrales utilizados para la discretización de los valores de RVR son los siguientes:

$$\text{Clase} = \begin{cases} \text{niebla,} & \text{si } RVR < 1000, \\ \text{neblina,} & \text{si } 1000 \leq RVR < 1990, \\ \text{no niebla,} & \text{si } RVR \geq 1990. \end{cases}$$

De esta forma, se obtiene un problema de clasificación con 3 clases, altamente desequilibrado, debido a que las condiciones de baja visibilidad son, afortunadamente, muy minoritarias respecto a situaciones de visibilidad óptima. La Tabla I muestra la proporción de las diferentes clases en los conjuntos de entrenamiento y generalización considerados.

Tabla I  
PROPORCIÓN DE CLASES

Clase	Entrenamiento	Generalización
niebla	856 (6%)	772 (12%)
neblina	912 (6%)	514 (8%)
no niebla	12294 (88%)	4740 (80%)
Total	14062 (70%)	6026 (30%)

## III. MODELOS UTILIZADOS

Una serie temporal se define como un conjunto de datos cronológicamente ordenados y muestreados con una frecuencia constante. Formalmente, una serie temporal unidimensional se define como:

$$Y = \{y_0, y_1, y_2, \dots, y_N\},$$

donde  $N$  es la longitud de la serie temporal.

La experimentación desarrollada en este artículo se ha llevado a cabo mediante el análisis de las series temporales descritas en la sección II-A, utilizando diferentes ventanas de valores pasados. Inicialmente, se crea un conjunto de patrones en los que la variable dependiente es el valor de la serie objetivo en el instante de tiempo a predecir y las variables independientes están formadas por la información extraída a partir de las ventanas. Con este conjunto de patrones, entrenamos cualquier modelo de aprendizaje automático, por lo que podríamos considerar que las ventanas actúan como un método de preprocesamiento.

### III-A. Extracción de características basada en ventanas

El análisis de series temporales mediante métodos autorregresivos permite modelar una variable en función de valores pasados, tanto de ella misma como de otras variables independientes relacionadas con el problema. En este artículo se propone el uso de 3 métodos, cada uno de los cuales limita de distinta forma la ventana de valores pasados utilizada para predecir el siguiente. Estos métodos pueden ser utilizados de forma individual, aplicando un único tipo de análisis,



o combinada, de forma que se pueda aunar la información obtenida mediante varios tipos de ventanas. La Figura 1 muestra gráficamente el funcionamiento de estos 3 métodos en un problema sintético: una serie temporal categórica asociada a una variable dependiente a predecir y una serie temporal de valores reales asociada a una variable independiente, correlada con la primera. En dicha figura, el valor de la serie dependiente a predecir se encuentra sombreado en azul, mientras que las ventanas utilizadas para ello se encuentran sombreadas en gris.

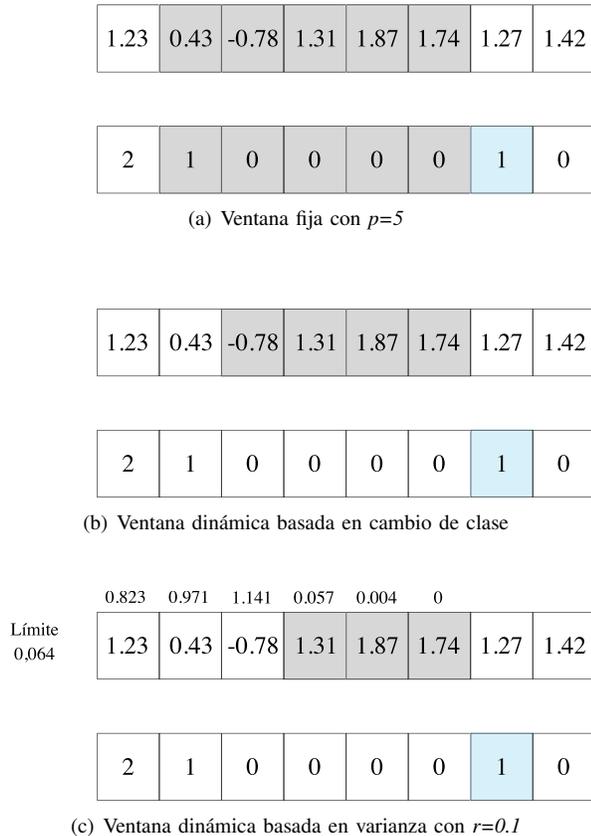


Figura 1. Distintos tipos de ventana propuestos.

**III-A1. Modelo de ventana fija (VF):** utiliza un número de instantes pasados constante para la predicción de cada valor de la serie temporal. Esta ventana es la que emplean los modelos autorregresivos (AR) clásicos, comúnmente utilizados en Estadística. El número de instantes es un parámetro del modelo,  $p$  (o orden del modelo AR), y los resultados obtenidos mediante este preprocesamiento son muy sensibles al valor de  $p$ . El modelo AR de orden  $p$  puede definirse como:

$$X_t = c + \sum_{i=1}^p \alpha_i X_{t-i} + \varepsilon_t \quad (1)$$

donde  $c$  representa una constante,  $\alpha_i$  el coeficiente correspondiente al valor de la serie temporal en el instante  $t - i$  y  $\varepsilon_t$  ruido blanco, esto es, una variable aleatoria Normal de media 0 y de varianza a determinar. En la Figura 1(a) se muestra

un ejemplo de este tipo de preprocesamiento haciendo uso de una ventana fija de tamaño 5. Como se puede ver en dicha figura, para predecir el valor sombreado en azul hace uso de los 5 valores anteriores de todas las series involucradas en el problema, tanto la dependiente como las independientes.

**III-A2. Modelo de ventana dinámica basada en cambio de clase (VDCC):** en series temporales categóricas, este modelo crea ventanas de tamaño variable limitándolas en base a los cambios de clase. De esta forma, para predecir un determinado valor, se identifica la clase inmediatamente anterior y se añaden valores anteriores mientras la clase no cambie, creándose ventanas más grandes cuando la clase es estable (existe una racha). En este tipo de preprocesamiento, los valores pasados de la serie dependiente son utilizados de forma indirecta dado que, aunque no se utilizan sus valores, son estos los que determinan el tamaño de las ventanas que se crean. En la Figura 1(b) se representa gráficamente la ventana creada para un determinado valor. En este ejemplo, la clase inmediatamente anterior al valor a analizar es 0, por lo que la ventana se extenderá hacia detrás, hasta que se encuentre una categoría distinta de 0, creando en este caso una ventana de 4 elementos. Tras ello, la información de las muestras de cada serie independiente que caigan dentro de la ventana se resume mediante las métricas detalladas en la sección IV-A.

**III-A3. Modelo de ventana dinámica basada en varianza (VDV):** en series temporales de valores reales, proponemos este modelo que crea ventanas de tamaño variable en función de la dinámica de la serie. Se analiza, de forma individual para cada serie temporal, la varianza de los valores incluidos en la ventana. Se añaden valores previos a la ventana hasta que se alcanza un determinado límite de varianza, que se establece como un porcentaje de la varianza total de la serie. Dicho porcentaje es un parámetro del modelo,  $r$ . La idea subyacente es que, cuando la varianza es demasiado alta, puede no tener sentido intentar resumir la información incluida en la misma. Además, dado que cada serie temporal se analiza de forma independiente, se pueden obtener ventanas de distinto tamaño para cada variable de entrada, cuando haya muchas variables independientes (como sucede en el problema considerado). La Figura 1(c) muestra un ejemplo de este procesamiento con un porcentaje de varianza total del 10%. Este procesamiento no puede aplicarse sobre la serie categórica. En la serie de valores reales, se muestra, sobre cada valor, la varianza parcial, de forma tal que la ventana utilizada para predecir el valor sombreado en azul crecerá mientras que la varianza parcial sea menor que el límite (10% de la total). Las ventanas serán resumidas mediante las métricas de la sección IV-A.

### III-B. Clasificadores

La información obtenida tras el uso de las diferentes combinaciones de ventanas será utilizada para entrenar clasificadores que realicen la predicción de la categoría. En una primera aproximación, hemos considerado algunos de los modelos más clásicos de los incluidos en *scikit-learn* [15], una librería de código abierto implementada en *Python*. De esta forma, los clasificadores considerados son: Regresión logística (RL) [11],

Árboles de decisión (AD) [12] y conjuntos de clasificadores (concretamente *RandomForest (RF)* [13] y *GradientBoosting-Classifier (GB)* [14]).

#### IV. EXPERIMENTACIÓN Y RESULTADOS

##### IV-A. Configuración

Como ya se especificó en la sección II-A, un 70% de los datos se ha empleado como conjunto de entrenamiento, mientras que el 30% formó el conjunto de *test*.

Para ambas ventanas dinámicas (tanto la basada en varianza como en el cambio de clase), se ha elegido resumir la información de las ventanas creadas utilizando dos estadísticos:

- La media aritmética ( $\overline{W}_s$ ) de la ventana, definida como:

$$\overline{W}_s = \frac{1}{s} \sum_{y \in W_s} y$$

donde  $s$  es el número de valores de la ventana y  $W_s$  la ventana creada.

- La varianza ( $S_{W_s}^2$ ), utilizada para obtener una medida de dispersión de los valores contenidos en la ventana y definida como:

$$S_{W_s}^2 = \frac{1}{s-1} \sum_{y \in W_s} (y - \overline{W}_s)^2.$$

Los parámetros de los métodos de preprocesamiento y de los clasificadores han sido optimizados mediante una validación cruzada anidada de tipo *5-fold*. A continuación se indican los valores explorados. Para el análisis de ventana fija, se ha utilizado un número de muestras previas  $p \in \{1, 2, 3, \dots, 6\}$ . Para el análisis de ventana dinámica basado en varianza, se ha optado por optimizar la proporción de varianza total utilizada para limitar las ventanas según  $r \in \{0, 1; 0,2; 0,3; \dots; 0,6\}$ .

Los parámetros de los modelos de clasificación también han sido optimizados mediante validación cruzada. Para RL, se ha optimizado la intensidad de la regularización mediante el parámetro  $C \in \{10^{-3}, 10^{-2}, \dots, 10^2, 10^3\}$ . Para los AD se ha optimizado la función para medir la calidad de una división, utilizando el coeficiente *Gini* y la entropía. En el caso de RF, se ha optimizado el número de árboles en cada bosque  $n \in \{10, 50, 100\}$ , y, para GB, el número de árboles utilizado en el algoritmo ha sido  $n \in \{50, 100, 150, 200\}$  y el ratio de aprendizaje  $l \in \{0,05; 0,1; 0,2; 0,3\}$ .

##### IV-B. Métricas de rendimiento

Existen multitud de métricas para evaluar la calidad de una clasificación obtenida. Una de las más comunes es el porcentaje de patrones bien clasificados (*Correct Classified Ratio, CCR*) con la que se obtiene una medida de rendimiento global. No obstante, el problema a tratar en este artículo es altamente desequilibrado, haciendo que cualquier clasificador trivial que clasifique todos los patrones en la clase mayoritaria obtenga buena puntuación en *CCR*. Por ello, el rendimiento ha de medirse mediante otras métricas. Hemos elegido la Media Geométrica de Sensibilidades (*Geometric Mean of the Sensitivities, GMS*), una medida de rendimiento que tiene en

cuenta la precisión de la clasificación en todas las clases. El *GMS* se define como:

$$GMS = \sqrt[n]{\prod_{i=1}^n S_i}$$

donde  $n$  es el número de clases y  $S_i$  la sensibilidad de la clase  $i$ -ésima, es decir:

$$S_i = \frac{n_i}{N_i}$$

siendo  $n_i$  el número de instancias de la clase  $i$  correctamente clasificadas y  $N_i$  el número total de instancias de la clase  $i$ . Es una medida a maximizar.

Por otro lado, la naturaleza ordinal de nuestro problema (las categorías están organizadas en una escala ordinal) hace que sea necesario obtener una medida de error que penalice más algunos tipos de errores (por ejemplo, la confusión de “no niebla” con “niebla alta”), para lo que se utilizará la Media de Errores Absolutos Medios (*Average Mean Absolute Error, AMAE*). El *AMAE* se define como:

$$AMAE = \frac{1}{n} \sum_{i=1}^n MAE_i$$

donde  $n$  es el número de clases y  $MAE_i$  es la desviación media producida con respecto a la clase real considerando solo la clase  $i$ . Se define como:

$$MAE_i = \frac{1}{N_i} \sum_{i=1}^{N_i} |C(y_i) - C(\hat{y}_i)|$$

siendo  $N_i$  el número de instancias de la clase  $i$ ,  $C(y_i)$  la clase real de la instancia  $i$  y  $C(\hat{y}_i)$  la clase predicha para la instancia  $i$ , representadas mediante valores numéricos (es decir,  $C(y_i) = 0$  para no niebla,  $C(y_i) = 1$  para no neblina y  $C(y_i) = 2$  para niebla). Al tratarse de una medida de error, es una métrica a minimizar.

Tabla II  
RESULTADOS DE *test* EN *GMS*

Tipos de ventanas	Clasificadores			
	GB	RF	RL	AD
VF	<u>0.624</u>	0.453	0.567	0.518
VDCC	0.286	0.375	0.297	0.405
VDV	0.0	0.072	0.278	0.286
VF+VDCC	0.617	<b>0.492</b>	0.547	<b>0.540</b>
VF+VDV	<u><b>0.656</b></u>	0.355	0.533	0.467
VDCC+VDV	0.475	0.368	0.442	0.425
VF+VDCC+VDV	0.620	0.447	<b>0.591</b>	0.469

##### IV-C. Resultados

Las Tablas II y III incluyen todos los resultados obtenidos, para *GMS* y *AMAE*, respectivamente. Por filas, se muestran las combinaciones de ventanas (ventana fija, VF, ventana dinámica basada en cambio de clase, VDCC, y ventana dinámica basada en varianza, VDV, más todas las combinaciones posibles, VF+VDCC, VF+VDV, VDCC+VDV y VF+VDCC+VDV) y por columnas cada uno de los 4



Tabla III  
RESULTADOS DE *test* EN *AMAE*

Tipos de ventanas	Clasificadores			
	GB	RF	RL	AD
VF	0.317	<b>0.373</b>	<i>0.314</i>	<i>0.437</i>
VDCC	0.538	0.592	0.419	0.660
VDV	<i>0.312</i>	0.406	0.333	0.442
VF+VDCC	0.314	0.385	0.318	<b>0.426</b>
VF+VDV	<b>0.304</b>	0.396	0.323	0.457
VDCC+VDV	<u>0.349</u>	0.412	<b>0.306</b>	0.474
VF+VDCC+VDV	<i>0.312</i>	<i>0.384</i>	<u>0.316</u>	0.461

clasificadores considerados. Los mejores resultados por cada clasificador se muestran en negrita, los segundos mejores en cursiva. El mejor resultado global se encuentra doblemente subrayado, mientras que el segundo mejor está marcado con subrayado simple.

Atendiendo a dichas tablas, se pueden obtener diversas conclusiones:

- En términos de *GMS*, los mejores resultados para cada modelo se obtienen siempre mediante un preprocesamiento en el que intervienen dos o más ventanas. En términos de *AMAE*, a excepción del modelo *Random-Forest*, ocurre lo mismo, lo que demuestra que el uso combinado de distintas ventanas mejora ampliamente los resultados obtenidos, en comparación con los obtenidos mediante el uso individual de los mismos.
- Al optimizar el *AMAE*, conviene utilizar la combinación de ventanas que produce el segundo mejor resultado, debido a que el tamaño del patrón que genera el uso de VDCC+VDV será mucho más pequeño que usar VF+VDV. Esto se debe a que el uso de ventanas dinámicas resume las muestras de las ventanas en dos métricas (media y varianza), haciendo que como máximo los patrones cuenten con 20 características. Atendiendo al *grid* de parámetros utilizados para ventana fija, los patrones generados con este método junto con la ventana dinámica pueden ser de hasta 40 características, ralentizando bastante el proceso de entrenamiento.
- La combinación VF+VDV consigue los mejores resultados, tanto en *GMS* como *AMAE*, mediante el uso del clasificador *GradientBoosting*. La ventana basada en varianza provee de una capacidad dinámica en el análisis de las series independientes, adaptándose a cada serie de forma individual, lo que combinado con una ventana fija que utilice muestras previas devuelva el mejor resultado.
- La VF siempre obtiene los segundos mejores resultados en *GMS*. Este aspecto era esperable, dado que existe una alta persistencia en la serie categórica dependiente a predecir. Así, en la optimización del tamaño de ventana fija, se incluye la posibilidad de crear ventanas de tamaño 1, haciendo que el modelo tienda a predecir la salida únicamente en función de un instante pasado. Aunque esto devuelva unos resultados aceptables, no es deseable, dado que este tipo de modelos nunca serán capaces de detectar un cambio de clase en la serie.

- El uso de un preprocesamiento VDV aislado devuelve unos resultados pobres. Esto es debido a que el uso de este tipo de ventanas está orientado a series reales, y al tratar con una serie dependiente de naturaleza categórica, la serie a predecir se modela únicamente en función de series independientes, perdiendo una parte importante de la información.
- Los resultados de *GMS* obtenidos con el uso de VDCC aislado, a pesar de utilizar solamente los valores de las series independientes, son mejores que los de VDV. La razón de este resultado es que, a pesar de que VDCC no usa los valores de la serie dependiente de forma directa, son éstos los que determinan el tamaño de ventana para cada muestra, por lo que de forma indirecta se está utilizando una información inherente a la serie dependiente.

Por último, la Figura 2 muestra una comparación de un fragmento de 96 horas de la serie real y la serie predicha por *GradientBoosting* con la mejor combinación de ventanas. Como puede observarse, el modelo funciona de forma aceptable, prediciendo correctamente los cambios producidos en las etiquetas reales. Tan solo en la última parte del gráfico se observan algunos artificios introducidos por el método.

## V. CONCLUSIONES

Este artículo evalúa el uso de diferentes clasificadores de aprendizaje automático para predecir eventos de baja visibilidad por niebla en el aeropuerto de Valladolid. Se realiza una predicción categórica basada en tres posibles tipos de situaciones (no niebla, neblina y niebla), utilizando como entrada valores pasados de un conjunto de variables meteorológicas medidas en el aeropuerto. Proponemos considerar distintos tipos de ventanas a la hora de analizar los valores pasados: ventanas fijas junto con dos tipos de ventanas dinámicas (una basada en cambios de la categoría de los días pasados analizados y otra basada en varianza de la variable independiente examinada). La ventaja fundamental de estos métodos dinámicos es que evitan fijar el tamaño de la ventana, pudiéndose adaptar de forma dinámica a la serie temporal considerada.

Los resultados obtenidos indican que la combinación de ventanas fijas y dinámicas (especialmente aquella basada en varianza), junto con el conjunto de clasificadores *GradientBoosting* obtiene los mejores resultados, con valores de *AMAE* cercanos a 0,3 (es decir, la predicción difiere en 0,3 categorías, en media, con respecto al valor real) y un *GMS* mayor que el 65%. Teniendo en cuenta estos resultados, se puede concluir que los modelos obtenidos pueden mejorar la seguridad y la eficiencia de las operaciones aeronáuticas que se llevan a cabo en aeropuertos bajo condiciones de baja visibilidad por niebla. Como trabajo futuro, planteamos el uso de clasificadores ordinales, dada la naturaleza ordinal de las clases consideradas.

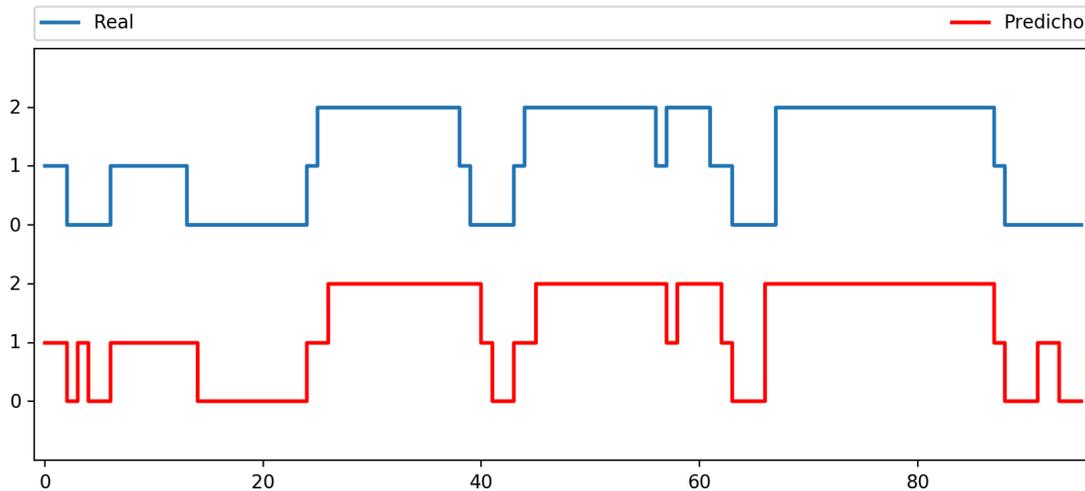


Figura 2. Comparación de etiquetas reales con las predichas por *GradientBoosting* con VF +VDV durante 96 horas. La clase 1 corresponde a no niebla, la clase 2 a neblina y la clase 3 a niebla.

#### REFERENCIAS

- [1] D. Koracin, C. E. Dorman, J. M. Lewis, J. G. Hudson, E. M. Wilcox and A. Torregrosa, "Marine fog: A review," *Atmospheric Research*, vol. 143, pp. 142-175, 2014.
- [2] I. Gultepe, et al., "Fog Research: A Review of Past Achievements and Future Perspectives," *Pure and Applied Geophysics*, vol. 164, pp. 1121-1159, 2007.
- [3] H. Huang and C. Chen, "Climatological aspects of dense fog at Urumqi Diwopu International Airport and its impacts on flight on-time performance," *Natural Hazards*, vol. 81, pp. 1091-1106, 2016.
- [4] N. Fedorova et al. "Fog Events at Maceio Airport on the Northern Coast of Brazil During 2002–2005 and 2007," *Pure and Applied Geophysics*, vol. 172, pp. 2727-2749, 2015.
- [5] L. Zhenling et al., "Novel forecasting model based on improved wavelet transform, informative feature selection, and hybrid support vector machine on wind power forecasting," *Journal of Ambient Intelligence and Humanized Computing*, pp. 1-13, 2018.
- [6] G. Noradin, A. Adel, S. Hossein and A. Oveis, "A new prediction model based on multi-block forecast engine in smart grid," *Journal of Ambient Intelligence and Humanized Computing*, pp. 1-16, 2017.
- [7] Miao, Y. and Potts, R. and Huang, X., and Elliott, G. and Rivett, R., "A Fuzzy Logic Fog Forecasting Model for Perth Airport," *Pure and Applied Geophysics*, vol. 169, pp. 1107-1119, 2012.
- [8] D. Duta and S. Chaudhuri, "Nowcasting visibility during wintertime fog over the airport of a metropolis of India: decision tree algorithm and artificial neural network approach," *Natural Hazards*, vol. 75, pp. 1349-1368, 2015.
- [9] L. Cornejo-Bueno, C. Casanova-Mateo, J. Sanz-Justo, E. Cerro-Prada and S. Salcedo-Sanz, "Efficient Prediction of Low-Visibility Events at Airports Using Machine-Learning Regression," *Boundary-Layer Meteorology*, vol. 165, pp. 349-370, 2017.
- [10] J. Yan-jie, G. Liang-peng, C. Xiao-shi and G. Wei-hong, "Strategies for multi-step-ahead available parking spaces forecasting based on wavelet transform," *Journal of Central South University*, vol. 24, pp. 1503-1512, 2017.
- [11] J. P. Chao-Ying, L. L. Kuk and M. I. Gary, "An Introduction to Logistic Regression Analysis and Reporting," *The Journal of Educational Research*, vol. 96, pp. 3-14, 2002.
- [12] L. Wei-Yin, "Fifty Years of Classification and Regression Trees," *International Statistical Review*, pp. 329-348, 2002.
- [13] L. Breiman, "Random forests," *Machine Learning*, vol. 45(1), pp. 5-32, 2001.
- [14] J. F. Friedman, "Greedy Function Approximation: A Gradient Boosting Machine," *The Annals of Statistics*, vol. 29, pp. 1189-1232, 2001.
- [15] F. Pedregosa, "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825-2830, 2011.



# Intelligent Management of Measurement Units Equivalences in Food Databases\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

Beatriz Sevilla-Villanueva, Karina Gibert

*Department of Statistics and Operations Research*

*Universitat Politècnica de Catalunya-BarcelonaTech (UPC)*

Barcelona, Spain

Miquel Sànchez-Marrè

*Department of Computer Science*

*Universitat Politècnica de Catalunya-BarcelonaTech (UPC)*

Barcelona, Spain

**Abstract**—It is currently well-known that diet plays an important role in the promotion of healthy lifestyle and the prevention of chronic diseases. The Diet4You project is conceived to support the creation of an intelligent decision support system that provides personalized menus fitting a nutritional plan and taking into account the characteristics, needs and preferences of the person. The system involves a background food database, recording a collection of foods and prepared dishes with their standard portions as well as their nutritional decomposition in different food families. This DB is used to search the best combination of dishes approaching the total intake of different nutrients specified in the prescribed nutritional plan. The available background databases, specify the quantities of standard portions of several foods based on different measurement units which are not standardized, and it happens that the weight specified by one cup of melon is different from that of one cup of berries, among others. This arises the need of applying variable conversion factors to the dish description, before assessing whereas the total quantities of a certain menu fit well to the prescription. In this paper, a knowledge based approach is presented to the automatically management. An annotated reference food ontology is built on the basis of additional documentation. However the granularity of the information provided is heterogeneous and non exhaustive. The ontology-based missing values imputation is presented to overcome this limitations.

**Index Terms**—Ontology, Missing Imputation, Database

# Predicción de delincuencia con datos públicos

1<sup>st</sup> Roberto Cuesta Calvo  
*Servicios Técnicos. Servicio Informática*  
*Dirección General Guardia Civil*  
Madrid, España  
rcuesta@guardiacivil.es

2<sup>nd</sup> Jesús Maudes Raedo  
*Departamento de Ingeniería Civil*  
*Universidad de Burgos*  
Burgos, España  
jmaudes@ubu.es

3<sup>rd</sup> José-Francisco, Díez-Pastor  
*Departamento de Ingeniería Civil*  
*Universidad de Burgos*  
Burgos, España  
jfdpastor@ubu.es

4<sup>th</sup> Ivan Arjona  
*Departamento de Ingeniería Civil*  
*Universidad de Burgos*  
Burgos, España  
email iaa0037@alu.ubu.es

**Resumen**—La concentración de recursos policiales en lugares considerados conflictivos contribuye a la reducción de la criminalidad en los mismos y a la optimización de esos recursos. En este artículo se presenta la utilización de técnicas de regresión para predecir el número de hechos delictivos en los municipios españoles. Para ello, se ha generado un conjunto de datos que fusiona los datos de la Guardia Civil con datos públicos sobre la estructura demográfica y las tendencias de voto en los municipios. El mejor regresor obtenido (i.e., Random Forests) alcanza con estos datos un RRSE (raíz del error cuadrático relativo) del 41,23 %, y abre el camino para seguir incorporando datos públicos de otro tipo que tengan un mayor poder predictivo. Asimismo, se han utilizado reglas M5Rules para interpretar en lo posible los resultados.

**Index Terms**—datos públicos, minería de datos, predicción de hechos

## I. INTRODUCCIÓN

Para toda Fuerza y Cuerpo de Seguridad del Estado encargado de velar por los derechos y libertades de los ciudadanos se establece el concepto de territorialidad como un concepto clave en la búsqueda de maximizar la eficacia de sus recursos.

Es por ello que es constante el estudio estadístico de la criminalidad para optimizar la disposición de la fuerza sobre el terreno. Este estudio, constante en el tiempo, se acrecenta, aún mucho más, en épocas de crisis económica, pues es aquí donde existe una tendencia marcada en reducir recursos precisamente cuando, por diferentes y obvios motivos, existe riesgo de aumentar la criminalidad.

Si se deja a un lado la investigación en cibercriminalidad y fraudes, la utilización de técnicas de aprendizaje automático en la predicción de delitos comunes ha sido muy escasa. Sólo en los últimos tiempos empiezan a aparecer algunos trabajos prometedores en esta línea. El enfoque del presente trabajo consiste en relacionar datos demográficos y de tendencia de voto en los municipios españoles, con los hechos delictivos cometidos durante un año; para así predecir la criminalidad de los municipios en función de dichas variables.

Trabajo parcialmente financiado por el proyecto TIN2015-67534-P del Ministerio de Economía Industria y Competitividad.

En este sentido, el estudio que se asemeja más al presentado en este artículo es quizás el de Alves y otros [1], que aplican técnicas de regresión con Random Forests [5] para predecir la cantidad de homicidios urbanos en Brasil a través de los datos sociológicos y demográficos de las ciudades. Las predicciones alcanzan un coeficiente de determinación de 0.97. Los autores apuntan al desempleo y el analfabetismo como las principales variables que utiliza su modelo predictivo.

Existen otros estudios en ámbitos geográficos más reducidos. En [17] se estudian cuales son las zonas conflictivas de un distrito policial al objeto de planificar la acción de las patrullas de calle. Se trabaja con los datos de Los Angeles (EEUU) y Kent (GB), y utilizan una aproximación basada en series temporales para estudiar la evolución de esas zonas.

En [15] se utilizan SVMs para predecir si una zona es conflictiva o no, en Columbus (Ohio) y St. Luis (Missouri).

En [7] se analizan las zonas de riesgo de crímenes sexuales en el campus de Charlottesville de la Universidad de Virginia. Se utilizan los clasificadores regresión logística y Random Forests [5] para clasificar un punto como conflictivo o no. Establece como variables mas importantes la proximidad de personas con antecedentes en violencia sexual y de residencias con fraternidades estudiantiles. También utilizan una aproximación de series temporales para analizar el intervalo horario, día de la semana y época del año con mayor riesgo; así como la influencia de las condiciones meteorológicas, hallando la temperatura como factor climatológico más determinante. Utilizan *Kernel Density Estimation* (KDE) para comparar las probabilidades de riesgo en los distintos periodos de tiempo.

También se han utilizado técnicas de *Deep Learning* en la predicción de crímenes [14]. En este caso, las redes profundas predicen localizaciones y momentos probables de criminalidad en la ciudad de Chicago. Este estudio fusiona datos socioeconómicos con los datos policiales, además de datos climáticos. Otro trabajo en la misma línea para la ciudad de Manila es el de Báculo y otros [3]; en esta ocasión son las Redes Bayesianas el algoritmo de clasificación de entre los testados que mejores resultados ofrece.



El estudio que se presenta en el presente trabajo abarca todo tipo de delitos en la geografía Española. A diferencia de buena parte de los trabajos anteriormente revisados, no considera la evolución temporal de los hechos delictivos; ya que se centra en predicciones para todo el año; y además del uso de datos demográficos, presenta como novedad el uso de datos de preferencias políticas obtenidos a partir de los resultados electorales. Los resultados obtenidos son un primer paso dentro un proyecto que pretende integrar más datos públicos para mejorar las predicciones, pero que en el estado actual ya ofrece unos resultados interesantes.

El artículo se estructura como sigue; en la sección II se describen los datos y su procedencia, en la sección III se describen los experimentos con distintas técnicas de regresión para predecir los hechos delictivos, la sección IV trata de interpretar los resultados obtenidos, y finalmente en V se muestran las conclusiones y líneas futuras.

## II. OBTENCIÓN Y DESCRIPCIÓN DE LOS DATOS

Para este trabajo se han cruzado datos públicos de organismos oficiales con estadísticas de la Secretaría de Estado de seguridad a través de la Dirección General de la Guardia Civil.

Se entiende como datos públicos o abiertos aquellos que deben estar disponibles de manera libre, para acceder, utilizar, modificar y publicar sin restricciones de *copyright* [19].

Este trabajo se aprovecha de propuestas como la ‘Iniciativa Aporta’ [2] que promueve la apertura de información en el sector público en España. Esta iniciativa tiene el objetivo de favorecer el desarrollo de la reutilización de la información del sector público y ayudar a las administraciones para que publiquen sus datos de acuerdo al marco legislativo vigente.

Los gobiernos tienen la capacidad de obtener grandes cantidad de información sobre la población a través de varios organismos (como podría ser el *Instituto Nacional de Estadística*).

En este trabajo cada instancia del conjunto de datos representa un municipio. El número de registros del conjunto es 8.125, con un total de 124 atributos sin contar la clase (i.e., número de hechos delictivos). Se han utilizado dos fuentes públicas:

1. Instituto Nacional de Estadística (INE). Estadísticas del año 2016, correspondientes a lugar de nacimiento y rangos de edad. Un total de 114 atributos. Lugar de nacimiento (51 atributos), Rangos de edad (63 atributos).
2. Ministerio de Interior. Datos electorales, elecciones al Congreso (Junio 2016). Un total de 10 atributos.

Los atributos de lugar de nacimiento se distribuyen en 17 categorías, cada una de ellas desglosada en 3 sub-categorías (mujeres y hombres, solo mujeres, solo hombres), las categorías son: 1) Total, 2) Españoles, 3) Nacidos en España, 4) En la misma Comunidad Autónoma, 5) Misma Comunidad Autónoma. Misma Provincia, 6) Misma Comunidad Autónoma. Misma Provincia. Mismo Municipio, 7) Misma Comunidad Autónoma. Misma Provincia. Distinto Municipio, 8) Misma Comunidad Autónoma. Distinta Provincia, 9) En distinta Comunidad Autónoma, 10) Nacidos en el Extranjero, 11) Nacionalidad extranjera, 12) Europa, 13) Unión Europea,

14) África, 15) América, 16) Asia, 17) Oceanía, Apátridas y Resto.

Los atributos de rangos de edad se distribuyen en 21 categorías (0-4 años, 5-9 años, ..., 90-94 años, 95-99 años, más de 100 años) cada una de ellas desglosada en 3 sub-categorías (mujeres y hombres, solo mujeres, solo hombres).

El número de votos de cada formación se ha agrupado en 10 categorías (Extrema Izquierda, Izquierda, Centro Izquierda, Centro, Centro Derecha, Derecha, Extrema Derecha, Otros, En blanco y Nulos.). En búsqueda optimizar la objetividad de las conclusiones finales estas categorías fueron seleccionadas y categorizadas por fuentes abiertas y externas al personal de este estudio, con el objeto de no introducir subjetividades que pudiesen introducir errores o inducir a conclusiones erróneas.

En cuanto a la clase, en los 8.125 municipios evaluados se registraron un total de 36.806.873 hechos, de los cuales, los más comunes fueron: Delito de hurto (11,5%), Infracción por el consumo o la tenencia de drogas en lugares públicos (9,4%), Robo con fuerza (8,8%), Infracciones al reglamento de vehículos (5,4%), Infracciones al reglamento de circulación (3,9%) y Alcoholemia (3,7%).

Es importante recalcar la naturaleza pública y externa a la Guardia Civil de los datos utilizados, y que dicha institución está, por tanto, al margen de cómo se han categorizado los mismos tanto en general, como en particular en lo concerniente a cómo se han agrupado los partidos políticos y a cómo se han agrupado los inmigrantes por su procedencia.

## III. ANÁLISIS DE LOS DATOS CON MÉTODOS DE REGRESIÓN

El conjunto de datos de la sección anterior sufrió dos transformaciones antes de ser utilizado. En primer lugar, se normalizaron todos los atributos, excepto la variable a predecir en el intervalo [0,1]. En segundo lugar, dado que la variable a predecir representa un recuento (i.e., *Nº de hechos delictivos*), se asume que sigue una distribución de Poisson, por lo que se ha aplicado la raíz cuadrada a dicha variable.

Una vez transformados los datos se procedió a experimentar en WEKA [12] mediante validación cruzada  $10 \times 10$  diversas técnicas de regresión, para así conocer la más idónea. En principio, en todos los regresores se ha utilizado la configuración por defecto de WEKA, salvo en los casos en los que a continuación se indique lo contrario.

Los regresores utilizados en el experimento se agrupan en dos familias: por un lado regresores en solitario o *singletons*, y por otro multiregresores o *ensembles*.

Entre los *singletons* se probaron:

- Árbol de decisión M5P [20]. Los M5P son árboles de decisión de la familia de los *model trees*. Estos árboles contienen una regresión lineal en los nodos hoja.
- M5Rules [13], se trata de un método que obtiene reglas de decisión a partir de árboles M5P, por lo que no se espera que den unos resultados muy distintos que el propio M5P. La razón de incluirlos es justificar su fiabilidad cara a utilizarlos en la sección IV como herramienta para interpretar los resultados.

- Regresión Lineal, optimizando el parámetro *ridge* para cada una de las cuatro versiones que se probaron, y que surgieron de activar/desactivar la selección de variables y la eliminación de atributos colineales. Se tomó como mejor versión la que no hacía selección de variables pero si eliminaba atributos colineales.
- SVM para regresión (SVM-Reg) [21] utilizando la implementación LIBLINEAR [9] con kernel lineal y el parámetro C optimizado.
- *k*-NN. Debido al elevado número de características en el conjunto de datos, se probaron dos versiones. La primera sin selección de atributos, la segunda con selección de atributos mediante *Correlation-based Feature Subset Selection* [11]. En ambas versiones se optimizó el número de vecinos. La mejor versión resultó ser la que no hace selección de atributos, y es la que se reporta en el artículo.

Los *ensembles* probados fueron los siguientes:

- Random Forest [5].
- AdaBoost.R2 [8], se han probado tres configuraciones con función de pérdida lineal, cuadrática y exponencial. Se seleccionó la configuración con mejores resultados en la validación cruzada  $10 \times 10$  (i.e., pérdida cuadrática)
- Additive Regression, que es una implementación de *Stochastic Gradient Boosting* [10]
- Bagging [4]
- Iterated Bagging [6]. En este caso, para simular 100 árboles se utilizan 20 iteraciones Bagging de 5 árboles cada una.

Todos los *ensembles* utilizan 100 árboles M5P como regresores base, excepto Random Forest, que obviamente utiliza 100 Random Trees.

La métrica utilizada para evaluar los regresores es el RRSE o raíz del error cuadrático relativo, que para  $\theta_i$  el valor verdadero a estimar para la instancia  $i$ -ésima,  $\hat{\theta}_i$  el valor resultado de la estimación de esa instancia, y  $\bar{\theta}$  el valor medio de las  $\theta_i$ , estimado a través de las instancias del conjunto de entrenamiento, se define como:

$$RRSE = \sqrt{\frac{\sum_{i=1}^N (\hat{\theta}_i - \theta_i)^2}{\sum_{i=1}^N (\bar{\theta} - \theta_i)^2}}$$

Los resultados se muestran en el Cuadro I. Como se puede apreciar, los *ensembles* están a la cabeza, mientras que los métodos lineales quedan en la parte inferior. Esto puede deberse a que, como se indica en [16] la relación entre el tamaño de las ciudades y su criminalidad obedece más a una ley potencial que a una relación lineal. De hecho, los coeficientes de correlación en la tabla muestran una correlación muy discreta cuando se utilizan modelos lineales, que mejoran considerablemente en el caso de los árboles M5P y las reglas M5Rules, los cuales también usan modelos lineales en las hojas, y alcanzan un valor aproximado de 0.9 *ensembles* utilizados.

El mejor método, tanto por RRSE, como por coeficiente de correlación, es *Random Forests*. El RRSE alcanzado, 41.23,

Método	RRSE	Coef. Corr.
Random Forests	41.23	0.91
AdaBoost R2	41.63	0.91
Bagging	42.20	0.91
Iterated Bagging	43.42	0.90
Additive Regression	44.62	0.90
M5P	47.10	0.88
M5Rules	49.41	0.87
<i>k</i> -NN	52.27●	0.85●
SVM-Reg	74.59●	0.67●
Regresión Lineal	82.15●	0.62●

Cuadro I

RESULTADOS DE LOS DIFERENTES MÉTODOS ORDENADOS POR RRSE. LOS ● INDICAN DIFERENCIAS SIGNIFICATIVAS CON EL MEJOR MÉTODO.

parece mostrar que los datos demográficos y de intención de voto sirven para explicar aceptablemente la concentración de hechos delictivos, pero quizás aún hay margen de mejora incorporando en el futuro nuevas variables al modelo.

En la tabla se ha marcado con ● aquellos valores que son estadísticamente peores, con un nivel de confianza del 95 %, al compararlos con el mejor método. El test estadístico utilizado es el *corrected resampled t-test* [18], debido a su idoneidad en el caso de utilizar validación cruzada. Se aprecia que no hay diferencias entre los métodos del grupo de los *ensembles*.

#### IV. INTERPRETACIÓN DE LOS RESULTADOS DEL ANÁLISIS Y LÍNEAS DE MEJORA

Para descubrir las posibles líneas de mejora del modelo actual se han seguido dos caminos:

- Investigar los municipios en los que peor se comporta el modelo.
- Generar reglas con el algoritmo *M5Rules* [13], para poder interpretar el conjunto de datos.

##### IV-A. Municipios que peor responden al modelo

Para tener una lista ordenada de los municipios que peor responden al modelo se halló el valor absoluto de la diferencia entre el número de hechos real y el número de hechos predichos por un *Random Forest* entrenado con todos los datos del conjunto. Cierto es que esta diferencia arroja unos valores muy optimistas, en tanto las diferencias se obtienen a partir de predicciones sobre los propios datos de entrenamiento, pero se asume que esa ventaja la van a tener todos los municipios. Una vez obtenida esa diferencia en valor absoluto, se divide por el número de habitantes del municipio, para evitar que el indicador únicamente señale a los municipios más grandes. Denotaremos a este indicador como  $\Delta/\text{hab}$ .

El valor máximo de  $\Delta/\text{hab}$  es del 29,99 %, y se alcanza en un municipio de 230 habitantes. Hay otro pequeño municipio de 20 habitantes que alcanza un 29,75 %, otro de 105 con un 24 %, y a partir de ahí una lista de 35 pequeños municipios, el mayor de ellos con 303 habitantes, hasta llegar a *Sant Josep de sa Talaia* con 25.849 habitantes y un  $\Delta/\text{hab} = 7,32$  %.

En estas localidades tan pequeñas, cuando ocurren unos pocos hechos delictivos por encima de los previstos, el indicador  $\Delta/\text{hab}$  se dispara.



Es llamativo que en esta lista ordenada por  $\Delta/\text{hab}$  hay una serie de municipios de más de 10.000 habitantes intercalados con estos pequeños municipios. El Cuadro II muestra los que tienen un  $\Delta/\text{hab}$  por encima del 2%.

Municipio	Nº hab	$\Delta/\text{hab}$	Hechos	Predicción	pos
S. Josep de sa Talaia	25.849	7,32 %	5.578	3.685	38
Calvià	49.580	4,79 %	6.281	3.907	80
Torreveija	84.213	3,18 %	7.312	4.635	149
S. Antony de Portmany	24.478	2,96 %	3.260	2.536	177
Borriana	34.643	2,29 %	2.347	1.556	254
Las Rozas de Madrid	94.471	2,16 %	4.160	2.126	276
Benicasim	17.957	2,03 %	1.356	991	301
Guardamar del Segura	15.386	2,02 %	1.280	969	304

Cuadro II

MUNICIPIOS CON MÁS DE 10.000 HABITANTES Y  $\Delta/\text{hab} > 2\%$ .  
POS=POSICIÓN EN EL RANKING.

Estas localidades podrían estar siendo predichas mal debido a que en su mayoría son conocidas plazas turísticas, y su tamaño real, teniendo en cuenta los turistas, seguramente difiera mucho del tamaño por habitantes empadronados. De hecho, todas las predicciones son siempre a la baja. No obstante, los valores de  $\Delta/\text{hab}$  son bastantes moderados.

Por tanto, se aprecia que una línea de mejora a futuro podría venir por incorporar al conjunto de datos características nuevas que cuantifiquen el fenómeno turístico en los municipios.

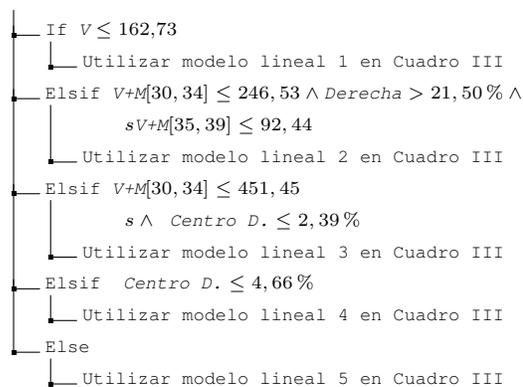
#### IV-B. Interpretación con M5Rules

Se ha utilizado para interpretar el conjunto de datos la generación de reglas mediante el algoritmo *M5Rules* [13]. *M5Rules* genera un árbol M5P, selecciona la mejor hoja, y haciendo AND con los nodos en el recorrido entre la raíz y dicha hoja, genera una primera regla. Después, descarta del árbol los datos que han caído en esa hoja, y vuelve a construir un nuevo M5P repitiendo todo el proceso para generar una segunda regla, y así sucesivamente va generando nuevos árboles por cada regla con los datos de entrenamiento que no son cubiertos por las reglas anteriores, hasta que finalmente a toda instancia la corresponda una regla.

La implementación WEKA de *M5Rules*, en la configuración por defecto del algoritmo, incluye un proceso de poda, de manera que elimina las reglas finales, que tienden a concentrarse en casos particulares, sustituyéndolas por un modelo lineal.

En el cuadro I de la sección I podía verse que no hay diferencias significativas en términos de *RRSE* entre el mejor método y *M5Rules*, por lo que parece una aproximación aceptable para tener una cierta interpretación de los datos desde la óptica de los árboles de decisión.

Para ello, se utilizó el conjunto de entrenamiento al completo y se generaron las siguientes cinco reglas:



$V$  representa el número total de varones del municipio,  $V[x,y]$  representa el número de varones en el rango de edades  $[x,y]$ ,  $V+M[x,y]$  representa la suma de varones y mujeres en el rango de edades  $[x,y]$ , *Derecha* y *Centro D* es el porcentaje de votos a formaciones de derecha y de centro derecha respectivamente. La última regla (i.e., *ELSE*) no contiene una condición lógica por que es la que proviene de la poda de las reglas menos importantes, ya comentada anteriormente.

Nótese que las reglas de la ilustración no son las originales generadas por el algoritmo, el cual, como ya se ha indicado trabaja con datos normalizados en el intervalo  $[0,1]$ . En su lugar, y para facilitar su comprensión, esas reglas se han traducido con los valores correspondientes a los datos sin normalizar.

Se aprecia que las expresiones lógicas en las cinco reglas toman como variables los rangos de edad, prestando mucha atención a los rangos en torno a 30-39 años para caracterizar los cinco grupos de municipios. Es probable que el modelo esté tomando esas edades para caracterizar el tamaño de los municipios. Como novedad importante frente a otros trabajos relacionados, la orientación del voto también ha sido tenida en cuenta. Por el contrario, el origen de la población (e.g., extranjera, nacida en el mismo municipio, etc...) no ha sido utilizada.

Los cinco grupos generados por las reglas, se describen en el Cuadro IV, mientras que sus respectivos modelos lineales están en el Cuadro III. En dicho cuadro se ha incluido una columna *Peso* que se calcula a partir de los valores absolutos de los coeficientes, de manera que representa el cociente entre el valor absoluto del coeficiente de ese atributo, dividido por la suma de los valores absolutos de todos los coeficientes. Una vez calculado el peso, los atributos se ordenan por el mismo descendientemente. El cuadro solo muestra los de mayor absoluto, concretamente los necesarios para que su suma supere el umbral del 33,34 % del peso total.

Los modelos lineales de este cuadro son confusos y no arrojan conclusiones sobre la influencia de un determinado colectivo en la aparición de hechos delictivos. Esto se debe principalmente a las relaciones de inclusión que existen entre gran parte de los atributos. Es decir, algunos atributos representan colectivos que están incluidos dentro de colectivos representados por otros atributos. Por ejemplo, en el modelo

lineal número 1, aparentemente la variable más importante es el número de extranjeros americanos, que contribuye a la aparición de hechos delictivos con signo positivo y un peso del 8,01 %. Sin embargo, el coeficiente con tercer mayor peso son las mujeres de ese colectivo, que contribuyen negativamente con un peso del 4,70 %, mientras que los varones de ese colectivo están en undécimo lugar con un peso, también negativo del 2,93 %4, de manera que unos coeficientes están contrarrestando el peso de otros, y dado que el modelo está representando los coeficientes para predecir la raíz cuadrada de los hechos, no es directo establecer la contribución neta de los tres coeficientes. Hay más relaciones de inclusión, por ejemplo, en el modelo 2, los varones y mujeres de 30 a 34 años son un subconjunto de los varones y mujeres, y a la vez es superconjunto de los varones en ese rango de edad, etc ...

Modelo Lineal 1		
Coef.	Variable	Peso
+86.053,06	Americanos	8,01 %
-66.181,54	Varones+mujeres de 0 a 4 años	6,16 %
-50.466,39	Mujeres de América	4,70 %
-48.402,00	Varones+mujeres de 30 a 34 años	4,50 %
+40.735,51	Varones+mujeres de 40 a 44 años	3,79 %
+34.253,68	Varones+mujeres de 60 a 64 años	3,19 %
-33.294,81	Varones	3,10 %
+0,61	Término independiente	

Modelo Lineal 2		
Coef.	Variable	Peso
+31.480,21	Varones+mujeres de 30 a 34 años	16,76 %
-29.679,75	Varones+mujeres de 0 a 4 años	15,80 %
-15.372,52	Varones de 30 a 34 años	8,18 %
+2,07	Término independiente	

Modelo Lineal 3		
Coef.	Variable	Peso
-14.576,13	Extranjeros	21,68 %
+9.533,03	Mujeres extranjeras	14,18 %
+3,10	Término independiente	

Modelo Lineal 4		
Coef.	Variable	Peso
-295,28	Varones de 70 a 74 años	11,48 %
-250,56	Varones de 90 a 94 años	9,74 %
+247,15	Varones nacidos en el extranjero	9,61 %
-246,47	Mujeres asiáticas	9,58 %
+10,87	Término independiente	

Modelo Lineal 5		
Coef.	Variable	Peso
-120,03	Varones de 75 a 79 años	9,62 %
+118,35	Varones de 85 a 89 años	9,49 %
+110,85	Varones y mujeres de 80 a 84 años	8,88 %
-106,74	Mujeres nacidas en el extranjero	8,56 %
+0,126	Término independiente	

Cuadro III

MODELOS LINEALES OBTENIDOS PARA EL CONJUNTO DE REGLAS *M5Rules*. LA COLUMNA PESO REPRESENTA EL PESO DEL VALOR ABSOLUTO DE ESE COEFICIENTE EN EL MODELO LINEAL. SE MUESTRAN SOLO LOS DE MAYOR PESO.

Aunque los modelos lineales no parecen arrojar ninguna conclusión plausible, el análisis de los grupos que generan las reglas sí que es algo más revelador. En el Cuadro IV se han

incluido el mínimo, máximo, promedio y desviación típica de la población, número de hechos delictivos y  $\Delta/\text{hab}$  para cada uno de los grupos de municipios definidos por las cinco reglas. Asimismo, la Figura 1 muestra también para los cinco grupos cómo se distribuyen los hechos delictivos frente al tamaño de los municipios. Los colores en la figura representan valores  $\Delta/\text{hab}$  altos a medida que toman valores más claros.

Parece que los grupos correspondientes a las cuatro primeras reglas mantienen una cierta similitud en que simplemente constatan que a medida que aumenta el tamaño del municipio aumenta el número de hechos delictivos. En el grupo de la regla 1 llama la atención el máximo número de hechos (146 hechos en Escorca, Mallorca), que se corresponde con el municipio con el  $\Delta/\text{hab}$  máximo que ya se comentó en la sección IV-A. Todos los demás municipios de R1 excepto éste están, sin embargo, por debajo de los 45 hechos.

El ratio  $\Delta/\text{hab}$  es algo más grande para la regla R1 (promedio de 0,74 %), debido a que en los municipios pequeños se penaliza mucho una leve variación en unos pocos delitos, pero en los grupos R2 a R4 se estabiliza en torno a 0,30 %–0,38 %.

El grupo correspondiente a la regla R5, sin embargo, es diferente a los demás. A pesar de englobar municipios grandes y muy grandes, mantiene un promedio de hechos delictivos muy bajo (3,22). Un análisis identificativo de dichos municipios nos revela que son todos municipios de Cataluña y País Vasco, donde hay transferidas muchas competencias a las policías autonómicas, y donde por tanto, el número de denuncias que tramita la Guardia Civil tiende a ser marginal.

Por tanto, podemos apuntar como debilidad del modelo predictivo que no predice los hechos delictivos en sí, sino únicamente los denunciados a la Guardia Civil, como por otro lado es lógico, ya que son las denuncias que se han utilizado en el estudio. Por tanto, otra línea de mejora es la incorporación de datos de las policías autonómicas.

	R1	R2	R3	R4	R5
Municipios	3.118	1.846	1.437	830	894
Min Habs	5	258	299	4.027	291
Max Habs	341	2.036	8.483	3.165.541	1.608.746
Prom Habs	133,5	706,0	3.014,2	38.194,6	9.848,5
Dev Habs	79,2	342,0	1.574,4	127.095,5	58.499,7
Min Hechos	0	0	0	0	0
Max Hechos	146	85	459	10.025	792
Prom Hechos	2,55	14,32	70,06	542,83	3,22
Dev Hechos	4,31	11,22	55,25	775,15	27,86
Min $\Delta/\text{hab}$	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
Max $\Delta/\text{hab}$	29,99 %	10,50 %	5,90 %	7,30 %	0,70 %
Prom $\Delta/\text{hab}$	33,70 %	37,10 %	33,70 %	7,90 %	1,30 %
Prom $\Delta/\text{hab}$	0,74 %	0,38 %	0,30 %	0,37 %	0,03 %
Dev $\Delta/\text{hab}$	1,68 %	0,52 %	0,39 %	0,50 %	0,06 %

Cuadro IV

DESCRIPCIÓN ÁREAS CUBIERTAS POR CADA REGLA.  $R_i = N^\circ$  DE REGLA EN EL ORDEN DE INTERPRETACIÓN *M5rules*, MIN-MAX-PROM Y DEV = MÍNIMO, MÁXIMO, PROMEDIO Y DESVIACIÓN ESTÁNDAR RESPECTIVAMENTE. HABS= $N^\circ$  DE HABITANTES, HECHOS= $N^\circ$  HECHOS DELICTIVOS POR MUNICIPIO,  $\Delta/\text{HAB}$  =PORCENTAJE DE ERROR POR HABITANTE.

## V. CONCLUSIONES Y LÍNEAS FUTURAS

En el presente trabajo se ha obtenido un modelo predictivo basado en *Random Forests* que permite predecir el número

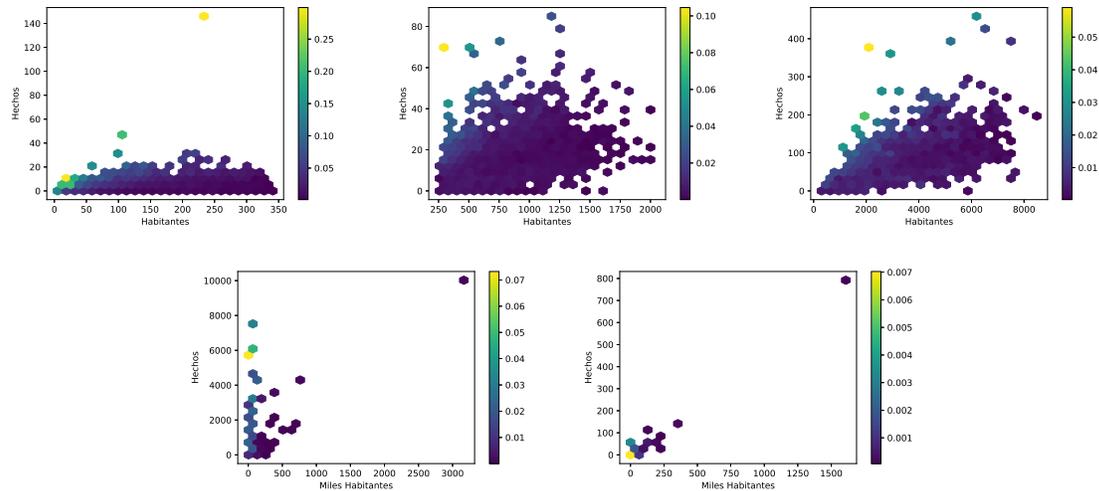


Figura 1. Un diagrama de *binning* hexagonal por cada uno de los subconjuntos resultantes de aplicar las reglas. En el eje *y* se muestran el número de habitantes, en el eje *x* el número de hechos y el color representa  $\Delta/\text{hab}$  en la predicción en los municipios situados en esas coordenadas

de hechos delictivos que se denuncian a la Guardia Civil anualmente en cada municipio. El valor de RRSE alcanzado es de 41.23, pero en general todos los *ensembles* dan resultados que no son significativamente diferentes.

Los datos utilizados combinan la localización de las denuncias de la Guardia Civil con fuentes de datos públicas (i.e., INE y datos electorales de 2016). Una novedad que incorpora el presente trabajo es precisamente la incorporación de datos electorales.

Del análisis de los municipios en los que peor se comporta el modelo se deriva una posible mejora incorporando datos relativos a la ocupación turística, probablemente enfocados al turismo de playa.

Por otro lado, las reglas *M5Rules* han discriminado cinco grupos de municipios. Los cuatro primeros grupos parecen segmentar los municipios por su tamaño. El quinto grupo aglutina las denuncias en las comunidades autónomas en las que la policía autonómica ha sustituido a la Guardia Civil en muchas de sus competencias; por lo que otra línea de mejora cara identificar puntos calientes, es incorporar datos de denuncias de esos cuerpos policiales.

#### REFERENCIAS

- [1] Luiz G.A. Alves, Haroldo V. Ribeiro, and Francisco A. Rodrigues. Crime prediction through urban metrics and statistical learning. *Physica A: Statistical Mechanics and its Applications*, 505:435 – 443, 2018.
- [2] Iniciativa Aporta. Acerca de la iniciativa aporta. <http://datos.gob.es/es/acerca-de-la-iniciativa-aporta>. [Internet; descargado 16-mayo-2018].
- [3] Maria Jeseca C. Baculo, Charlie S. Marzan, Remedios de Dios Bulos, and Conrado Ruiz. Geospatial-temporal analysis and classification of criminal data in manila. In *Procs. of 2nd IEEE International Conference on Computational Intelligence and Applications*, pages 6–11. IEEE, 2017.
- [4] Leo Breiman. Bagging predictors. *Machine Learning*, 24(2):123–140, Aug 1996.
- [5] Leo Breiman. Random forests. *Machine Learning*, 45(1):5–32, Oct 2001.
- [6] Leo Breiman. Using iterated bagging to debias regressions. *Machine Learning*, 45(3):261–277, Dec 2001.
- [7] Elise Clougherty, John Clougherty, Xiaoqian Liu, and Donald Brown. Spatial and temporal analysis of sex crimes in charlottesville, virginia. In *Procs. of IEEE Systems and Information Engineering Design Symposium*, pages 69–74. IEEE, 2015.
- [8] Harris Drucker. Improving regressors using boosting techniques. In *Proceedings of the Fourteenth International Conference on Machine Learning, ICML '97*, pages 107–115, San Francisco, CA, USA, 1997. Morgan Kaufmann Publishers Inc.
- [9] Rong-En Fan, Kai-Wei Chang, Cho-Jui Hsieh, Xiang-Rui Wang, and Chih-Jen Lin. LIBLINEAR: A library for large linear classification. *Journal of Machine Learning Research*, 9:1871–1874, 2008.
- [10] Jerome H. Friedman. Stochastic gradient boosting. *Comput. Stat. Data Anal.*, 38(4):367–378, February 2002.
- [11] M. A. Hall. *Correlation-based Feature Subset Selection for Machine Learning*. PhD thesis, University of Waikato, Hamilton, New Zealand, 1998.
- [12] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H. Witten. The WEKA data mining software: an update. *SIGKDD Explorations*, 11(1):10–18, 2009.
- [13] Geoffrey Holmes, Mark Hall, and Eibe Frank. Generating rule sets from model trees. In *Proceedings of the 12th Australian Joint Conference on Artificial Intelligence: Advanced Topics in Artificial Intelligence, AI '99*, pages 1–12, London, UK, UK, 1999. Springer-Verlag.
- [14] Hyeon-Woo Kang and Hang-Bong Kang. Prediction of crime occurrence from multimodal data using deep learning. *PLoS One*, 12(4):e0176244, 2017.
- [15] Keivan Kianmehr and Reda Alhaji. Effectiveness of support vector machine for crime hot-spots prediction. *Applied Artificial Intelligence*, 22(5):433–458, 2008.
- [16] J. C. Leitão, J. M. Miotto, M. Gerlach, and E. G. Altmann. Is this scaling nonlinear? *Royal Society Open Science*, 3(7), 2016.
- [17] G. O. Mohler, M. B. Short, Sean Malinowski, Mark Johnson, G. E. Tita, Andrea L. Bertozzi, and P. J. Brantingham. Randomized controlled field trials of predictive policing. *Journal of the American Statistical Association*, 110(512):1399–1411, 2015.
- [18] C. Nadeau and Y. Bengio. Inference for the generalization error. *Machine Learning*, 52(239–281), 2003.
- [19] Comisión Económica para América Latina y el Caribe. ¿qué son los datos abiertos? <https://biblioguias.cepal.org/EstadoAbierto/datospublicos>. [Internet; descargado 16-mayo-2018].
- [20] Ross J. Quinlan. Learning with continuous classes. In *5th Australian Joint Conference on Artificial Intelligence*, pages 343–348, Singapore, 1992. World Scientific.
- [21] Alex J. Smola and Bernhard Schölkopf. A tutorial on support vector regression. *Statistics and Computing*, 14(3):199–222, August 2004.



**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 4:  
METODOLOGÍAS







# Diagnóstico de fallos mediante clasificadores: Análisis de robustez en ambientes de incertidumbre

JM. Bernal-de Lázaro

Dept. de Automática y Computación  
Universidad Tecnológica de La Habana,  
Habana, Cuba  
jbernal@automatica.cujae.edu.cu

O. Llanes-Santiago

Dept. de Automática y Computación  
Universidad Tecnológica de La Habana,  
Habana, Cuba  
orestes@tesla.cujae.edu.cu

A. Prieto-Moreno

Dept. de Automática y Computación  
Universidad Tecnológica de La Habana,  
Habana, Cuba  
albprieto@automatica.cujae.edu.cu

A. Silva-Neto

Dept. de Ingeniería Mecánica  
Instituto Politécnico do Rio de Janeiro  
Rio de Janeiro, Brasil  
ajsneto@iprj.uerj.br

C. Cruz Corona

Dept. de Ciencia de la Computación  
Universidad de Granada  
Granada, España  
carloscruz@decsai.ugr.es

**Resumen**—La presencia de ruidos e interferencias es un fenómeno común en los procesos de transmisión y procesamiento de datos que se producen en ambientes industriales. Teóricamente, en ausencia de ruidos e interferencias, la información implícita en los datos transmitidos puede ser mejor aprovechada. Sin embargo, la realidad es que el ruido resulta intrínseco a los sistemas eléctricos y entornos industriales, por lo que es recomendable considerar su efecto al trabajar con la información de los sensores en el proceso. En este contexto, el problema de la robustez para sistemas de diagnóstico de fallos puede ser definido como la capacidad de maximizar la detectabilidad y aislabilidad de los fallos, al mismo tiempo que se minimiza el efecto de perturbaciones, ruidos y cambios en los estados del sistema. El objetivo de este trabajo es estudiar los enfoques de diagnóstico de fallos, con énfasis en su robustez y aplicación en ambientes industriales ruidosos. Para ello, se propone un índice que permite evaluar el desempeño global de un diagnosticador en términos de su robustez durante su etapa de diseño. El índice propuesto complementa el error de clasificación mediante un factor de penalización que refleja la capacidad de rechazo al ruido por parte del diagnosticador. Para ejemplificar la utilidad del índice propuesto, se compara el desempeño de tres clasificadores: Árboles de Decisión (AD-ID3), Redes Neuronales Artificiales (RNA) y Máquinas de Soporte Vectorial (MSV), aplicados todos al diagnóstico de fallos en el Tanque Reactor Continuamente Agitado (CSTR).

**Index Terms**—Diagnóstico de fallos; Clasificación; Robustez

## I. INTRODUCCIÓN

Durante los últimos 30 años, el diagnóstico de fallos (DF) como área de investigación, ha recibido una considerable atención [1], [2], [4], [5]. Estas publicaciones se centran en tres cuestiones primordiales dentro del diseño de los sistemas de diagnóstico de fallos, estas son: robustez, sensibilidad y rendimiento. De acuerdo con la definición dada por [9] y [10], el problema de la robustez en el diagnóstico de fallos puede entenderse como la capacidad de maximizar la detectabilidad y aislabilidad de los fallos, al mismo tiempo que se minimiza el efecto de perturbaciones, ruidos y cambios en las entradas/salidas, o estados del sistema. A partir de esta definición,

se han desarrollado numerosos estudios relacionados con el análisis de la robustez en sistemas de diagnóstico que utilizan modelos matemáticos puros. Sin embargo, muy pocos estudios han investigado el impacto del ruido en los sistemas de diagnóstico basados en datos históricos. En este contexto, el tema de la robustez ha sido abordado mayormente desde el punto de vista de la insensibilidad del sistema de diagnóstico a datos fuera de rango (*outliers*), datos ausentes (*missing data*), y valores muy puntuales de ruido. Aunque se han hecho progresos considerables en este sentido, un problema persistente en el campo del diagnóstico de fallos basado en datos es que los estudios comparativos entre clasificadores no consideran el efecto del ruido o simplemente realizan un análisis de robustez local simulando valores constantes para el ruido en los datos. Por lo general, estas comparaciones se enfocan en una zona de trabajo donde se asume niveles ruido muy bajos que se consideran invariantes. En los procesos reales, sin embargo, es posible que la conexión/desconexión de equipos y diferentes fuentes de ruido externas modifiquen los datos obtenidos del proceso, introduciéndoles mayor variabilidad. Se requiere, por tanto, de un indicador que cuantifique el desempeño del sistema de diagnóstico en términos de insensibilidad ante este cambio y permita comparar el desempeño de diferentes herramientas de clasificación empleadas en las tareas de diagnóstico de fallos. Una alternativa a este problema es el indicador de robustez aquí propuesto.

Para ello, la estructura de este trabajo es la siguiente. En la Sección 2 se discuten las consideraciones generales para el análisis de la robustez en sistemas de diagnóstico basados en datos. En la Sección 3 se realiza la propuesta de indicador de robustez, y se exponen sus aplicaciones potenciales. La aplicación del índice de robustez propuesto en el proceso de prueba Tanque Reactor Continuamente Agitado (CSTR) y el estudio comparativo de los clasificadores se realiza en la Sección 4. Por último, se emiten las conclusiones del trabajo.

## II. CONSIDERACIONES GENERALES

En el control de un proceso, una interferencia puede ser considerada como un tipo de perturbación externa generada por acoplamientos eléctricos y magnéticos (motores, equipos de alta potencia, etc), o debido a fenómenos naturales (tormentas, etc). Dado su origen conocido, el efecto de una interferencia periódica, intermitente, o aleatoria, puede ser minimizado por la sustitución de acoplamientos eléctricos y electromagnéticos; acciones que deben ir acompañadas además, del uso de conexiones apantalladas y protecciones eléctricas en las líneas de transmisión. Por otro lado, la contaminación de señales debido al ruido es un concepto más general al considerar cualquier efecto aleatorio e impredecible (con acción temporal o constante), que distorsiona una señal original que es medida, transmitida y procesada. El incremento en la variabilidad de los datos transmitidos suele ser, por lo general, uno de los efectos más notables en las señales ruidosas. Cuando variabilidad incorporada por el ruido adiciona incertidumbre a la información contenida en una señal, es posible que la información original sea parcialmente enmascarada, modificada o imposible de identificar.

Un ruido puede afectar significativamente el desempeño de un diagnosticador incorporando variabilidad adicional en los datos, lo cual modifica negativamente las fronteras de decisión del clasificador [11]. Este fenómeno es fácil de entender si consideramos al clasificador como un algoritmo o función matemática que divide el espacio de características (síntomas), en tantas regiones como clases (fallos) existen [7]. Por ejemplo, considérese un espacio de características consistente en dos clases mutuamente excluyentes. La tarea del clasificador de diagnóstico es asignar una etiqueta de clase  $\hat{y}_i$  a una nueva observación  $x_i = \{\nu_1, \dots, \nu_d\}$ , dado  $\hat{y}_i = f(x_i)$  con una etiqueta de clase predicha  $\hat{y}_i \in \{c_1, c_2\}$  y  $\nu_j$  variables medidas. El efecto del ruido en las mediciones puede hacer aparentemente similar el comportamiento de dos clases distintas, resultando en una mayor probabilidad de confundir los patrones de fallos diferentes.

Bajo esta filosofía, se pueden considerar varios escenarios cuando existe un aumento en la variabilidad de los datos. Una posible situación a considerar sería tener un diagnosticador robusto que mantiene un bajo error de clasificación, independientemente del nivel de variabilidad en los datos. Otro posible escenario es que, como resultado del efecto del ruido, el clasificador evaluado presente un deterioro importante en su desempeño mientras aumenta la variabilidad de los datos. A fin de comparar los clasificadores propuestos, en lo adelante, se establecerá que un diagnosticador robusto es aquel que mantiene altos indicadores de desempeño, independiente del efecto negativo de ruidos y/o perturbaciones externas. Desde el punto de vista de modelado se considerará, además, que se trata de un problema multivariable con  $k$  clases que representan los estados de operación del sistema, tal que el efecto de un ruido en las variables medidas puede ser modelado como:

$$X(t) = S(t) + \Gamma(t) \quad (1)$$

donde el comportamiento habitual en las mediciones del proceso es representado por  $S(t) \sim N(\mu_s, \Sigma_S)$  y  $\Gamma(t) \sim N(0, \sigma_\Gamma^2 I)$  es la incertidumbre adicional incorporada por el ruido. En procesos reales, por lo general, no se cuenta con información sobre el tipo y cantidad de ruido implícito en las mediciones; pero esta información puede ser supuesta apriori. Además, con el objetivo de facilitar el estudio de la robustez de los clasificadores, se asume que el ruido (i.i.d.) es acotado y cada columna de  $S(t)$  es de la forma  $s_j(t) \sim N(\mu_{s_j}, \sigma_{s_j}^2)$ , donde  $j = \{1, \dots, p\}$  denota la variable medida. A partir de esto,  $\mu_{s_j} \pm 3\sigma_{s_j}$  determina el rango específico dentro del cual se tiene un 99,73% de información válida para las distribuciones de cada una de las variables [6]. Por tanto, para una variabilidad en los datos que es acotada entre  $\pm 3\sigma_{s_j}$  respecto al comportamiento nominal del proceso,  $X(t)$  puede contener información de  $S(t)$ , incluso si  $\Gamma(t) \neq 0$ ; fuera de este intervalo es más difícil obtener altos desempeños en las tareas de clasificación debido a la mezcla de clases.

## III. ÍNDICADOR DE ROBUSTEZ PROPUESTO

El rechazo de ruido por nivel es la capacidad de un clasificador de no ser afectado por la variabilidad en los datos, como resultado de un ruido acotado. Entonces, la sensibilidad al ruido por parte del clasificador, representada matemáticamente por el índice de robustez  $J_{RIL}$  se determina como:

$$J_{RIL} = H [(I_m^1 + V) (I_{max}^0 - I_{min}^0)] \quad (2)$$

donde  $I_m^1$ ,  $I_{max}^0$  y  $I_{min}^0$  se calculan usando el método de los trapecios y brindan una medida del área bajo las curvas de tendencia del error de clasificación. Para un nivel de ruido, que varía con un incremento  $\Delta\eta$  en un rango de  $\eta_0 \leq \eta \leq \eta_{max}$ ,  $I_{min}^0$  y  $I_{max}^0$  son calculadas como sigue:

$$I_{lim}^0 = \int_1^q E_{lim} (f(X)|\eta_i) d\eta \quad (3)$$

$$I_{lim}^0 = \Delta\eta \left[ \frac{E_{lim}|\eta=\eta_0}{2} + \sum_{i=1}^{N_i-1} E_{lim}|\eta=\eta_i + \frac{E_{lim}|\eta=\eta_{i+1}}{2} \right] \quad (4)$$

Considerando que:

$$I_{lim}^0 = \begin{cases} I_{max}^0, & \text{si } E_{lim} = E_{max} \\ I_{min}^0, & \text{si } E_{lim} = E_{min} \end{cases} \quad (5)$$

La diferencia entre  $I_{max}^0$  y  $I_{min}^0$  modela el comportamiento del clasificador teniendo en cuenta el intervalo de confianza para cada uno de los errores estimados. Por otra parte,  $I_m^1$  está asociado con la tendencia del valor medio obtenido para el error de clasificación ( $E$ ).

$$I_m^1 = \int_1^q \eta_i^\ell \bar{E} (f(X)|\eta_i) d\eta \quad (6)$$

$$I_m^1 = \Delta\eta \left[ \eta_0^\ell \left( \frac{\bar{E}|\eta=\eta_0}{2} \right) + \sum_{i=1}^{N_i-1} \eta_i^\ell (\bar{E}|\eta=\eta_i) + \frac{\eta_{i+1}^\ell (\bar{E}|\eta=\eta_{i+1})}{2} \right] \quad (7)$$

En las ecuaciones (4) y (7) los valores constantes  $\eta_0$ ,  $\eta_{max}$  y  $\Delta\eta$  se definen por el investigador. La relación entre estos



parámetros está dada por  $H = \Delta\eta/(\eta_{max} - \eta_0)$ . En tanto, la variabilidad  $\sigma_\gamma$  adicionada por un ruido  $\Gamma(t)$  a una variable de  $S(t)$  es:

$$\sigma_\gamma = \sqrt{(\eta - 1)\sigma_s} \quad \eta \in \mathbb{R}^+, \eta \geq 1 \quad (8)$$

donde el nivel de severidad  $\eta$  que caracteriza la relación entre  $X(t)$  y  $S(t)$ , cuando los mismos proceden de una distribución normal, puede ser obtenido como:

$$\eta = \left( \frac{\Psi_X}{\Psi_S} \right)^2 = \left[ \frac{(\sigma_x/\mu_s) \times 100}{(\sigma_s/\mu_s) \times 100} \right]^2 \quad (9)$$

En este contexto, el parámetro  $V$  considera la rapidez con que se deteriora el desempeño del clasificador a medida que se incrementa la variabilidad en los datos y está dado por:

$$V = \sum_{i=2}^N (\bar{E}_i - \bar{E}_{i-1}) / (\eta_i - \eta_{i-1}) \quad (10)$$

donde  $\ell \in \mathbb{N}$  es un parámetro de magnificación usado en (7) y (10), a fin de penalizar aquellos clasificadores que ante elevados niveles de ruido, presentan un deterioro significativo en su desempeño. Diferentes valores de este parámetro, permiten dar mayor peso al comportamiento del clasificador según  $I_m^1$  o  $V$ . Para todos los casos analizados en el presente trabajo, el valor de este parámetro se fijó como  $\ell = 2$ .

#### IV. ROBUSTEZ DEL DIAGNÓSTICO EN EL CSTR

A continuación se evalúa la aplicación del índice de robustez  $J_{RIL}$  en el conocido proceso de prueba Tanque Reactor Continuamente Agitado (CSTR). Para ello, se emplean tres clasificadores diferentes y se incorpora variabilidad en el proceso según el esquema mostrado en la Figura 1.

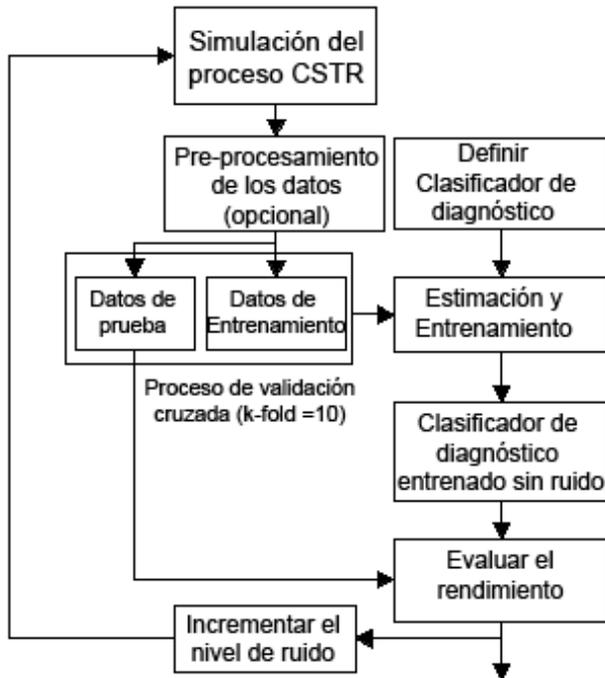


Figura 1. Flujograma empleado para los experimentos en el CSTR.

Para realizar la comparación de los clasificadores, se generan 91 conjuntos de datos históricos. El primer conjunto, describe la operación del CSTR considerando sólo la variabilidad típica en el proceso, y se utiliza para entrenar fuera de línea, cada uno de los clasificadores. Los conjuntos de datos históricos restantes, están asociados con la operación del proceso, a medida que se va incrementando el efecto del ruido. Todos los datos son recopilados fuera de línea, considerando la misma estructura y número de clases. Es decir, cada conjunto de datos históricos se forma a partir de nueve clases con 800 observaciones, que corresponden a cada uno de los fallos descritos en la Tabla I.

Cuadro I  
DESCRIPCIÓN DE LOS FALLOS EN EL PROCESO CSTR.

No.	Descripción de los fallos	Valor
1	Variación abrupta en el flujo ( $Q_F$ )	10 L/min
2	Temperatura del reactor con una desviación	4 K
3	Incremento en la concentración (Aumento de $C_{AF}$ )	Pendiente $6 \cdot 10$ (mol/L)/min
4	Incremento en la concentración (Aumento de $C_{AF}$ )	Pendiente 0,1 K/min
5	Aumento de la temperatura (del flujo refrigerante $T_{CF}$ )	Pendiente 0,1 K/min
6	Variación abrupta en la presión en la línea de enfriamiento ( $P_U$ )	2,5 psi
7	Variación abrupta en la presión en la línea de salida del reactor ( $P_D$ )	5 psi
8	La válvula del refrigerante presenta juego. 20% del span	

En todos los casos, los datos generados son sometidos a un paso intermedio donde se estandarizan de acuerdo con el estado de operación normal. El error obtenido por los clasificadores, se almacena en cada iteración. Posteriormente, se determina el índice de robustez para  $1 \leq \eta \leq 10$  y  $\Delta\eta = 0,1$ . El papel de los clasificadores consiste en identificar correctamente a cuál de los estados de fallos conocidos, corresponde una nueva observación del proceso.

#### IV-A. Clasificadores empleados.

En la literatura han sido abordadas múltiples herramientas discriminantes, con diferentes grados de éxito durante su aplicación a los problemas de diagnóstico de fallos. Seguidamente se presentan los aspectos básicos relacionados con las herramientas discriminantes utilizadas para probar el índice de robustez  $J_{RIL}$ .

**Árboles de Decisión:** Un Árbol de Decisión (AD) constituye un conjunto de condiciones organizadas en una estructura jerárquica para clasificar clases disjuntas. Cada rama, desde la raíz a las hojas, se puede interpretar como una regla, siendo los nodos hojas la clase asignada y los nodos internos los términos en conjunción (antecedente de la regla). Durante la clasificación con esta herramienta, cada elemento de su dominio es mapeado en un elemento de su rango, el cual es típicamente un identificador de clase o un valor numérico. En cada hoja del árbol se encuentra un elemento de rango;

mientras que en cada nodo interno se encuentra una prueba que tiene un conjunto de posibles resultados. Aunque este tipo de herramienta de clasificación no es la más competitiva en términos de predicción, en el presente trabajo se seleccionó para evaluar el índice de robustez propuesto por su simplicidad, fácil implementación e interpretación.

Hay varios enfoques para el diseño de estructuras de arboles e pueden ser empleados. [8]. En este caso el AD fue implementado comenzando desde la raíz, donde se encuentra la variable medida que mayor información ofrece. Su construcción avanza a partir de las ramas del árbol, que son las variables ordenadas a partir de la información discriminante que ofrece cada una, hasta llegar a las hojas que corresponden con la clasificación de los fallos. Este procedimiento es conocido como Inducción de Arriba hacia Abajo (por su denominación en idioma inglés: *Top-Down Induction of Decision Trees*) [13]. El clasificador basado en Árboles de Decisión [12], fue implementado usando el algoritmo de partición ID3. A partir de minimizar criterios de entropía, este algoritmo determina el árbol que genera menor cantidad de encuestas a los sensores y que dispone de la información más rápidamente.

**Redes Neuronales Artificiales:** La siguiente herramienta discriminante que es probada, se basa en el uso de las Redes Neuronales Artificiales. Los clasificadores de este tipo, se caracterizan por su tolerancia al ruido y su capacidad para generalizar la información, por tanto, son ideales para evaluar el índice de robustez propuesto. En este caso, se utiliza una Red Neuronal del tipo perceptrón multicapa cuyos parámetros de entrada y salida están asociados con la cantidad de variables del proceso y el número de fallos, respectivamente. En este sentido se desarrolla una arquitectura con una sola capa oculta con 9 neuronas, que posee 14 entradas y 9 salidas que permiten distinguir los fallos simulados en el CSTR. La red fue creada, entrenada e implementada utilizando el algoritmo de entrenamiento Levenberg–Marquardt. El proceso de entrenamiento se realizó de manera iterativa para minimizar el error cuadrático medio (MSE, *Mean Squared Error*) entre la salida de la red y el vector de entrenamiento. En cada iteración, el gradiente del desempeño de la función MSE fue utilizado para ajustar los pesos y umbrales de la red. En este estudio, se empleó un  $MSE = 10^{-6}$ , y un valor mínimo para el gradiente de  $10^{-8}$ , así como un número máximo de épocas igual a 100. El proceso de entrenamiento de la red, se detiene si cualquiera de las condiciones anteriores se cumple. Los pesos iniciales de la red fueron generados de manera aleatoria.

**Máquinas de Soporte Vectorial:** Las Máquinas de Soporte Vectorial, representan un clasificador basado en funciones kernel que es relativamente nuevo. Su principio de operación se fundamenta en la idea de usar un hiperplano para crear un clasificador, cuyo margen de separación entre clases sea máximo. En un problema de clasificación binario,  $\mathbf{w}$  es interpretada como la región entre los hiperplanos paralelos tal que  $f(x) = \mathbf{w}^T \mathbf{x}_i + \mathbf{w}_0 = \pm 1$ .

A partir de esto, la distancia de cualquier punto localizado en uno de los dos hiperplanos a la función de clasificación es igual a  $\mathbf{d} = 1/\|\mathbf{w}\|$ . La formulación del hiperplano queda definida entonces como:

$$J(\mathbf{w}, \mathbf{w}_0, \xi) = \min_{\mathbf{w} \neq 0} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^{\ell} \xi_i \quad (11)$$

$$\text{suje}to \ a : \quad y_i(\mathbf{w}^T + \mathbf{w}_0) \geq 1 - \xi_i \quad \xi_i \geq 0$$

donde  $y_i \in \{-1, 1\}$  corresponde a la etiqueta de la clase asociada y  $C$  es el parámetro de regularización mediante el cual se logra un balance entre el error cometido y el ancho del margen. En caso de que  $x_i$  sea clasificada correctamente pero fuera del margen entonces,  $\xi_i = 0$ ; si por el contrario, se encuentra dentro de éste, entonces  $0 \leq \xi_i \leq 1$  y si  $\xi_i$  está mal clasificada  $\xi_i \leq 1$ . Utilizando la representación del problema en su forma dual, es posible entonces evaluar las condiciones de Karush-Kuhn-Tucker para obtener el correspondiente vector  $\alpha = (\alpha_1, \dots, \alpha_\ell)$  de multiplicadores de Lagrange positivos. Cuando el conjunto de entrenamiento no es linealmente separable, se adopta la filosofía kernel para mapear los vectores característicos hacia un espacio de mayor dimensión, donde las clases son linealmente separables. Como resultado es posible reescribir el problema dual, tal que:

$$W(\alpha) = \max_{\alpha \neq 0} \sum_{i=1}^{\ell} \alpha_i - \frac{1}{2} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} \alpha_i \alpha_j y_i y_j \mathbf{K}_{ij} \quad (12)$$

Sustituyendo el producto punto por  $\mathbf{K}_{ij} = \mathbf{k}(x_i, x_j)$  se obtiene la función de decisión generalizada mostrada anteriormente, tal que la misma queda expresada como:

$$f(x) = \mathbf{w}^T \mathbf{x}_i + \mathbf{w}_0 = \text{sign} \left( \sum_{i=1}^{sv} \alpha_i y_i \mathbf{k}(x_i, x_j) + \mathbf{w}_0 \right) \quad (13)$$

donde  $sv$  corresponde a los vectores soportes obtenidos para  $\alpha_i$  multiplicadores de Lagrange que son no nulos. Para el diseño del clasificador MSV, en este caso se optó por utilizar la estrategia binaria (1 vs. Todos). De esta manera se requieren solo  $(c - 1)$  máquinas soporte. Este enfoque de clasificación se implementó utilizando un kernel Gaussiano, cuyo parámetro de ajuste fue estimado con la medida Alfa propuesta por [3].

#### IV-B. Análisis y discusión de los resultados

A fin de evaluar el desempeño de los clasificadores de diagnóstico en el CSTR, se realizan dos experimentos que consisten en incorporar ruido en las variables Flujo del refrigerante ( $C_{AF}$ ) y Concentración de alimentación ( $Q_C$ ) de dicho proceso. El primer paso de cada uno de los experimentos, se centra en determinar el error de clasificación cuando los datos históricos tienen el nivel de ruido que normalmente influye sobre el sistema. De esta manera, es posible conocer el valor medio del error, que se desea mantener para cada uno de los clasificadores a medida que se va incrementando la variabilidad de los datos durante los sucesivos pasos del procedimiento para calcular  $J_{RIL}$ .

Las Tablas II, IV y III, ilustran los resultados obtenidos para el primer paso del procedimiento. Nótese que los mejores



resultados se obtienen con las MSV, seguidas por las RNA y el clasificador AD. La diferencia entre el desempeño de los clasificadores es pequeña, y hace pensar que desde el punto de vista práctico es equivalente utilizar cualquiera de ellos como diagnosticador.

Cuadro II  
MATRIZ DE CONFUSIÓN OBTENIDA PARA EL CLASIFICADOR AD.

	NOC	F1	F2	F3	F4	F5	F6	F7	F8	TA(%)
NOC	717	0	83	0	0	0	0	0	0	89.63
F1	0	800	0	0	0	0	0	0	0	100.0
F2	211	0	589	0	0	0	0	0	0	73.63
F3	11	0	1	788	0	0	0	0	0	98.50
F4	0	0	0	0	800	0	0	0	0	100.0
F5	0	0	0	0	0	800	0	0	0	100.0
F6	0	0	0	0	0	0	800	0	0	100.0
F7	0	0	0	0	0	0	0	800	0	100.0
F8	11	0	1	0	0	0	0	0	788	98.50
TA(%)	75.5	100	87.4	100	100	100	100	100	100	95.58
E(%)	24.5	0	12.6	0	0	0	0	0	0	4.42

Cuadro III  
MATRIZ DE CONFUSIÓN OBTENIDA PARA EL CLASIFICADOR RNA.

	NOC	F1	F2	F3	F4	F5	F6	F7	F8	TA(%)
NOC	619	0	181	0	0	0	0	0	0	77.38
F1	0	800	0	0	0	0	0	0	0	100.0
F2	114	0	685	1	0	0	0	0	0	85.63
F3	6	0	2	792	0	0	0	0	0	99.00
F4	0	0	0	0	800	0	0	0	0	100.0
F5	0	0	0	0	0	800	0	0	0	100.0
F6	0	0	0	0	0	0	800	0	0	100.0
F7	0	0	0	0	0	0	0	800	0	100.0
F8	5	0	1	0	0	0	0	0	794	99.25
TA(%)	85.12	100	77	99.99	100	100	100	100	100	95.7
E(%)	14.88	0	23	0.001	0	0	0	0	0	4.30

Cuadro IV  
MATRIZ DE CONFUSIÓN OBTENIDA PARA EL CLASIFICADOR MSV.

	NOC	F1	F2	F3	F4	F5	F6	F7	F8	TA(%)
NOC	711	0	89	0	0	0	0	0	0	88.88
F1	0	800	0	0	0	0	0	0	0	100.0
F2	182	0	618	1	0	0	0	0	0	77.25
F3	15	0	1	784	0	0	0	0	0	98.00
F4	0	0	0	0	800	0	0	0	0	100.0
F5	0	0	0	0	0	800	0	0	0	100.0
F6	0	0	0	0	0	0	800	0	0	100.0
F7	0	0	1	0	0	0	0	799	0	99.86
F8	16	0	3	0	0	0	0	0	781	97.63
TA(%)	73.37	100	88.25	99.99	100	100	100	100	100	95.74
E(%)	26.63	0	11.75	0.001	0	0	0	0	0	4.26

Al menos para este nivel de variabilidad en los datos, las Tablas II, IV y III muestran que la precisión se encuentra siempre por encima del 95% lo que denota una elevada certeza en las decisiones tomadas usando este criterio. A fin de complementar estos resultados, en la Figura 2 se muestra el comportamiento de cada clasificador, teniendo en cuenta

el incremento en la variabilidad de los datos. Nótese que el análisis de robustez que mediante el índice  $J_{RIL}$  se muestra en la Figura 2 refleja que el desempeño anterior se deteriora significativamente a medida que aumentan los niveles de variabilidad en los datos como resultado de un ruido.

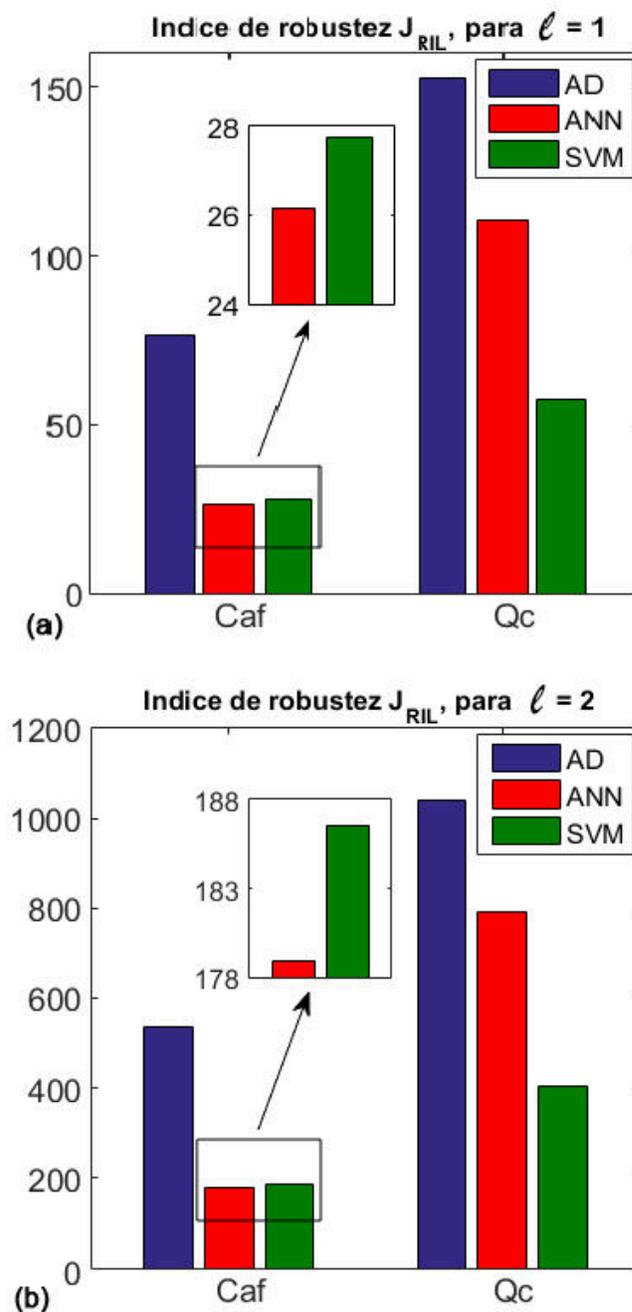


Figura 2. Comparando clasificadores mediante el índice de robustez  $J_{RIL}$ .

En este caso cuando la variable  $C_{AF}$  se encuentra afectada por diferentes niveles de ruido, el clasificador con mejor desempeño está basado en Redes Neuronales. En tanto, las Máquinas de Soporte Vectorial resultan el clasificador más robusto cuando la variable  $Q_C$  está expuesta a diferentes

niveles de ruido. Según se ilustra en la Figura 2, el parámetro de magnificación  $\ell$  permite resaltar las diferencias entre valores de robustez similares. Al comparar las gráficas de barras anteriores, es notable que el sistema de diagnóstico diseñado es más sensible al efecto del ruido en  $Q_C$  que en  $C_{AF}$  independientemente del clasificador empleado. En específico, el mayor deterioro se presenta para el clasificador basado en la herramienta de Árboles de Decisión. Teniendo en cuenta los resultados mostrados anteriormente, y considerando la similitud en el desempeño de los clasificadores sin un incremento de la variabilidad típica del proceso, se podría decir que en este caso no es recomendable emplear un clasificador basado en Redes Neuronales o en Árboles de Decisión. Una alternativa viable sería, seleccionar las Máquinas de Soporte Vectorial como clasificador a utilizar dado el alto rendimiento y nivel de rechazo al ruido que esta herramienta obtuvo durante las pruebas realizadas.

## V. CONCLUSIONES

En el presente trabajo se discutió la influencia negativa del ruido en los procesos de clasificación que forman parte de las tareas de diagnóstico de fallos. Además, se resaltó la necesidad de contar con sistemas de diagnóstico que sean robustos ante ruidos y/o perturbaciones, manteniendo altos indicadores de rendimiento. A fin de identificar cuáles son las herramientas de clasificación que cumplen estos requisitos, se evaluó el índice de robustez  $J_{RIL}$  usando el proceso CSTR. Los resultados obtenidos de estos experimentos mostraron que el índice propuesto permite, a partir de un único valor, establecer cuál es el clasificador más robusto, dado un ruido que afecta a las señales medidas con un rango de variabilidad conocido. Sin embargo, el indicador propuesto no brinda información específica sobre el deterioro que tiene el clasificador a medida que aumenta la variabilidad en los datos. En este sentido, es recomendable complementar el índice de robustez con una representación gráfica del deterioro del diagnosticador. De esta manera sería posible valorar la sensibilidad del clasificador analizado e identificar además, posibles alternativas de hibridación que permitan alcanzar rendimientos superiores en términos de robustez. La ventaja del índice propuesto, respecto a otros análisis de robustez local, radica en la capacidad de decisión que a partir de un único valor numérico brinda este indicador. Al utilizar el índice de robustez  $J_{RIL}$  no solo se reduce el número de análisis comparativos a realizar, sino que además, se evita considerar cualquier criterio subjetivo a la hora de seleccionar las herramientas de clasificación más adecuadas.

## VI. AGRADECIMENTOS

Los autores agradecen el apoyo financiero brindado por la Asociación Universitaria Iberoamericana de Postgrado (AUIP). También agradece la colaboración del Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) en Brasil, y de la Universidad Tecnológica de la Habana, CUJAE. Así como los Proyectos TIN201786647-P y TIN2017-86647-P (MINECO/AEI/FEDER, UE).

## REFERENCIAS

- [1] M. Blanke, M. Kinnaert, J. Lunze, M. Staroswiecki, *Diagnosis and Fault-Tolerant Control*, Springer, 2006.
- [2] L. H. Chiang, R. D. Braatz, E. L. Russell, *Fault detection and diagnosis in industrial systems*, Springer, 2001.
- [3] P. Chudhary, "Evaluation measures for kernel optimization", *Pattern Recognition Letters*. 33, 1108–1116, 2012.
- [4] A. Das, J. Maiti, R. Banerjee, "Process monitoring and fault detection strategies: A review", *International Journal of Quality and Reliability Management*, 29(7), 720–752, 2012.
- [5] S. X. Ding, *Data-driven Design of Fault Diagnosis and Fault-tolerant Control Systems*, Springer, 2014.
- [6] D. C. Montgomery, *Introduction to Statistical Quality Control*, Wiley and Sons, 2005.
- [7] J. Korbicz, *Fault diagnosis: Models, Artificial Intelligence, Applications*, Springer Science and Business Media, 2003.
- [8] J. Hernández-Orallo, M.J. Ramírez-Quintana, C. Ferri, *Introducción a la Minería de Datos*, Prentice Hall and Addison-Wesley, 2004.
- [9] R.J. Patton, J. Chen, *Robust model-based fault diagnosis for dynamic systems*, Kluwer Academic Publishers, London, 1999.
- [10] K. Patan, M. Witczak, J. Korbicz, "Towards robustness in neural network based fault diagnosis", *International Journal of Applied Mathematics and Computer Science*. 18, 443–454, 2008.
- [11] J. A. Sáez, M. Galar, J. Luengo, F. Herrera, "Analyzing the presence of noise in multi-class problems: Alleviating its influence with the One-vs-One decomposition", *Knowledge and Information Systems*. 38 (2014) 179–206.
- [12] J. R. Quinlan, "Induction of decision trees", *Machine Learning*, 1(1):81–106, 1986.
- [13] L. Rokach, O. Maimon, "Top-down induction of decision trees classifiers: A survey", *IEEE Transactions on Systems, Man, and Cybernetics*, 35(4):476–487, 2005.



# shinytests: Una herramienta gráfica para la comparación estadística en minería de datos

Jacinto Carrasco\*, Salvador García\* and Francisco Herrera\*

\* Dpto. de Ciencias de la Computación e Inteligencia Artificial

Universidad de Granada

Granada, España

Email: {jacintocc, salvagl, herrera}@decsai.ugr.es

**Resumen**—Los test estadísticos constituyen el procedimiento más fiable para la validación de los resultados obtenidos en múltiples escenarios. En particular, debido a su robustez y aplicabilidad, los test no paramétrico son una herramienta habitual y útil en el proceso de diseño y evaluación de los algoritmos de aprendizaje automático para ámbitos tanto de clasificación como de optimización. Las nuevas tendencias como el uso de test bayesianos y la observación de la distribución del parámetro de interés representan un enfoque a tener en cuenta.

En esta contribución se presenta la aplicación shiny de R *shinytests*, la cual integra test bayesianos y no paramétricos para facilitar la realización de test estadísticos en la comparación de algoritmos de aprendizaje automático y optimización.

**Index Terms**—Test estadísticos, test bayesianos, software, shinyapp, R

## I. INTRODUCCIÓN

En el desarrollo de algoritmos de aprendizaje automático y de optimización existe una necesidad creciente de validar y examinar la incertidumbre presente en estos procesos. Los test estadísticos son la herramienta recomendada para asegurar que las conclusiones obtenidas de los correspondientes experimentos no están sesgadas por la intención del investigador o se han obtenido por una cuestión de azar [1].

Existen numerosos test que pueden usarse para este propósito, los cuales pueden ser clasificados en dos grandes categorías: Los test frecuentistas, principalmente los test de hipótesis nula [2] o NHST (*Null Hypothesis Statistical Tests*), y los test bayesianos [3]. El primer grupo está subdividido en test paramétricos, que no se tendrán en cuenta en este artículo por estar suficientemente extendidos, y los test no paramétricos [4], los cuales requieren unas condiciones de aplicabilidad menos estrictas que los test paramétricos aunque esto se traduzca en ocasiones en una menor habilidad para encontrar diferencias existentes entre los resultados de los algoritmos [5]. Estos prerrequisitos son habitualmente la normalidad de la muestra o la homocedasticidad, condiciones que pueden ser comprobadas mediante test no paramétricos como el test de Kolmogorov-Smirnov, así como otros test sobre ciertas propiedades de la muestra, como la aleatoriedad de una muestra o el ajuste a una distribución. Para la comparación del desempeño de algoritmos se usan habitualmente los test de Wilcoxon de

rangos con signo o el test de Friedman para la comparación de múltiples algoritmos. Además de un resumen descriptivo de los test incluidos, se incluye un caso del uso de la aplicación shiny de R para la aplicación de los test bayesianos y la obtención de las gráficas correspondientes de la distribución del parámetro de interés, lo que ayuda a comprender estos test y sintetiza la información dada por éstos.

Esta contribución está organizada de la siguiente manera. En la Sección II se introducen los conceptos estadísticos necesarios y se describen los diferentes test estadísticos. En la Sección III se describen los principales métodos incluidos en la aplicación y se muestran varios ejemplos de su uso. En la Sección IV se concluye la contribución.

## II. ANTECEDENTES

En la Subsección II-A se introducen conceptos básicos de estadística que den soporte al resto del artículo. A continuación, en la Subsección II-B se describe el uso de los test frecuentistas clásicos para la comparación de algoritmos, con especial interés en los test no paramétricos. Los test bayesianos para la comparación de la eficacia de algoritmos se incluye en la Subsección II-C.

### II-A. Conceptos preliminares

En la inferencia estadística estamos interesados en obtener una predicción fiable a partir de los datos, por lo que debemos evitar llegar a conclusiones erróneas producidas por efectos aleatorios. Los principales conceptos a tener en cuenta son [2]:

- Los resultados de los algoritmos implicados en la comparación constituyen una **muestra**. Esta representa el desempeño del algoritmo sobre uno o varios problemas, ya sea la medida de ajuste sobre un problema de optimización o bien el acierto sobre un conjunto de datos en un problema de clasificación. Desde el punto de vista estadístico, esta muestra proviene de una distribución de probabilidad desconocida y será usada para inferir información relevante.
- Al hablar del **parámetro** de interés, o de la distribución de un cierto parámetro, nos referimos a la medida usada para evaluar la diferencia entre los resultados de los algoritmos, o bien el ajuste de una muestra con respecto a una distribución.

Este trabajo se ha sustentado por el proyecto de investigación TIN2017-89517-P. J. Carrasco disfruta de una beca FPU del Ministerio de Educación de España.

- Un enfoque frecuentista para inferir información relevante consiste en el cálculo de un estadístico, es decir, un estimador de una característica de la distribución.
- La **distribución** de la cual obtenemos la muestra es desconocida, por lo que los estadísticos se usarán para estimar el parámetro de interés.

## II-B. Test frecuentistas

Los test frecuentistas son la herramienta más común en la comparación del desempeño de algoritmos hasta ahora [6]. En ellos, se establece una hipótesis nula ( $\mathcal{H}_0$ ) y una hipótesis alternativa ( $\mathcal{H}_1$ ). Entonces, haciendo uso de una muestra se calcula la probabilidad de obtener una muestra tan alejada de la hipótesis nula como la que disponemos asumiendo que  $\mathcal{H}_0$  es cierta. Esta probabilidad se conoce como  $p$ -valor [2]. Entonces, si la probabilidad obtenida es menor que un valor fijo  $\alpha$  (normalmente 0,05), se rechaza  $\mathcal{H}_0$ , mientras que de otra manera no hay suficiente evidencias como para rechazar la hipótesis nula.

- Además, como estamos interesados en la comparación estadística, debemos prestar atención a las propiedades de los test estadísticos. Se define el **error de tipo I** como la probabilidad de rechazar la hipótesis nula  $\mathbf{H}_0$  cuando es cierta y el **error de tipo II** cuando  $\mathbf{H}_0$  no se rechaza y es falsa.
- La principal medida de para comparar la calidad de un test es la **potencia**, es decir, la probabilidad de rechazar  $\mathcal{H}_0$ . Estaremos interesados en obtener una mayor potencia manteniendo el error de tipo I, que se representa con el parámetro  $\alpha$ .

*II-B1. Test paramétricos:* Estos test parten de la suposición de que la muestra proviene de una familia conocida de distribuciones, habitualmente la distribución normal. Cuando se cumple la hipótesis de normalidad se obtiene un test más potente. Los principales test que se corresponden con esta categoría son el  $t$ -test para la comparación de dos muestras pareadas y el test ANOVA para la comparación de múltiples algoritmos. En ambos test la hipótesis nula consiste en la equivalencia de la media del desempeño de los algoritmos involucrados.

*II-B2. Test no paramétricos:* Los test no paramétricos no asumen que la muestra provenga de una distribución de una familia conocida [7], lo que se traduce en que se tengan condiciones menos restrictivas sobre la muestra, como la simetría o la continuidad [8]. En consecuencia, los test no paramétricos son más robustos que los paramétricos, puesto que normalmente no se dan las condiciones necesarias para su uso.

Para asegurarnos de que estamos usando correctamente el test ANOVA o el  $t$ -test debemos comprobar la normalidad de la muestra, para lo que pueden usarse test sobre la bondad del ajuste para, al menos, no rechazar esta hipótesis. Sirven para ello test de bondad del ajuste como los test de Kolmogorov-Smirnov, Shapiro-Wilk y D'Agostino-Pearson [9].

El test no paramétrico recomendado para la comparación de algoritmos depende del número de algoritmos a comparar y distintas situaciones implicadas:

- **Test de signo y Test de Rangos con signo de Wilcoxon:** El test de signo es un análogo del  $t$ -test simple y el test de Wilcoxon es la versión análoga del  $t$ -test pareado.
- **Test de Friedman:** Este test cumple con la función análoga al test paramétrico ANOVA. Se realiza una comparación de  $k$  algoritmos en  $n$  problemas (conjuntos de datos o funciones *benchmark*). El estadístico se calcula en base al orden de los algoritmos para cada problema. El test de Iman-Davenport constituye una propuesta más potente basada en el test de Friedman.
- **Test de Friedman de rangos alineados:** Esta mejora del test de Friedman usa el orden de los resultados en todos los problemas, lo que se traduce en que es tenida en cuenta la dificultad de cada problema.

En el caso de que existan diferencias significativas en la realización de test para múltiples algoritmos y se rechace la hipótesis nula  $\mathcal{H}_0$ , nuestro propósito será discernir dónde se encuentran estas diferencias. Para este paso es necesario un ajuste en el  $p$ -valor obtenido para mantener el control sobre el *Family-wise Error Rate* (FWER). Algunos ejemplos de test post-hoc son los de Bonferroni-Dunn, Holm, Holland, Hochberg o Li [6], [10], [11].

## II-C. Test bayesianos

Un enfoque distinto es el propuesto por Benavoli *et al.* [12]. La principal diferencia es que no se establece una hipótesis nula sobre el parámetro de interés para realizar un test de hipótesis nula, sino que se obtiene una distribución de probabilidad sobre el parámetro de interés.

*II-C1. Comparación con los test frecuentistas:* Según Benavoli [13], las principales diferencias que se podrían identificar son:

- En los test frecuentistas, las decisiones sobre la significatividad de un test son dicotómicas, basadas en el  $p$ -valor y el nivel  $\alpha$  de significatividad. En la estadística bayesiana, no existe un umbral fijo para el rechazo de la hipótesis nula sino la distribución del parámetro, de donde obtenemos la probabilidad de que la hipótesis nula sea cierta.
- En la aplicación de los NHST existe una confusión habitual, y es que el  $p$ -valor no representa la probabilidad de que se dé la hipótesis nula, sino, asumiendo que la hipótesis nula es cierta, obtener una muestra tan alejada de  $\mathcal{H}_0$  como la que disponemos. Normalmente queremos responder la primera pregunta, la cual obtenemos usando los test bayesianos.
- Una crítica común a los NHST es que el tamaño del efecto y el tamaño de la muestra no son distinguibles. Esto significa que un efecto tan pequeño como sea necesario puede ser considerado como significativo si se añaden suficientes instancias a la muestra. Como el tamaño de la muestra depende del investigador, se



podría variar el número de observaciones hasta obtener el resultado esperado.

- Los NHST no ofrecen información cuando la hipótesis nula no se rechaza. En esta situación, no podríamos decir que no hay diferencia entre las muestras, sino que no disponemos suficientes evidencias para rechazar la hipótesis nula. En cambio, en los test bayesianos la distribución del parámetro es informativa aunque no indique una suficiente diferencia entre los algoritmos.
- El proceso para realizar un test bayesianos consiste en establecer un modelo probabilístico *a priori* (basándonos en la información que disponemos o con una distribución *a priori* poco informativa), calcular e interpretar la distribución *a posteriori* basándonos en los datos disponibles, y evaluar el modelo.

*II-C2. t-test bayesiano correlado:* Esta versión bayesiana del *t*-test se usa para comparar los resultados de dos algoritmos de clasificación en un escenario de validación cruzada con *k* folds partition [14]. Este test tiene en consideración la correlación entre los distintos folds y parte de la hipótesis de que los datos vienen de una distribución gaussiana multivariante cuya matriz de covarianza depende de la correlación  $\rho$  entre los folds. Debido a que  $\rho$  no puede estimarse a partir de los datos, se utiliza la heurística sugerida por Nadeau y Bengio [15] y  $\rho = \frac{n_{test}}{n_{tot}}$ , esto es, el número de instancias en la partición de evaluación partido por el número total de instancias. Se parte de una distribución Normal-Gamma como la distribución *a priori* de la diferencia entre los algoritmos, por lo que se obtiene *a posteriori* una distribución de Student sobre la diferencia entre las medias  $\mu$ . Debemos además considerar la posibilidad de que no haya una diferencia significativa entre el desempeño de ambos algoritmos, por lo que se debe definir una región de equivalencia (a la que llamaremos *rope*, por *region of practical equivalence*),  $[r_{min}, r_{max}]$ , definida para  $\mu$ , y las relaciones entre los algoritmos se considerarán en términos de la *rope*. Por ejemplo, para  $a_1, a_2$  algoritmos involucrados en la comparación,  $P(a_1 \gg a_2) = P(\mu > r_{max})$  o  $P(a_1 = a_2) = P(\mu \in rope)$ , donde la relación entre los algoritmos se refiere a la comparación del desempeño de ambos algoritmos. La *rope* por tanto nos permite realizar decisiones automáticas, aunque volviendo de esta manera a la pérdida de información y las decisiones dicotómicas. Sin embargo, en esta ocasión la interpretación de las probabilidades son directas y los límites para las decisiones pueden variar en función del contexto.

*II-C3. Test bayesiano de signo:* La versión bayesiana del test no paramétrico de signo hace uso del Proceso de Dirichlet (DP, *Dirichlet Process*) [16]. Podemos entender este proceso como una distribución de probabilidad sobre una familia de distribuciones de probabilidad, de manera que la inferencia se realiza en dos pasos.

- En primer lugar se obtiene la función de densidad de la distribución *a posteriori* como una combinación lineal de deltas de Dirac centradas en las observaciones, cuyos pesos provienen de una distribución de Dirichlet.

- Entonces, aproximamos la anterior función de probabilidad *a posteriori* como una probabilidad *a posteriori* de la que podemos calcular la probabilidad del parámetro de pertenecer a cada región de interés.

*II-C4. Test bayesiano de rangos con signo:* La versión bayesiana de rangos con signo tiene el mismo *background* estadístico que el test bayesiano de signo. También hace uso del DP como el método para realizar la inferencia a partir del datos. La diferencia radica en el hecho de que el test de rangos con signo usa dos muestras y la comparación entre ellas en el cómputo de las probabilidades de las posibles relaciones entre algoritmos. En este test no obtenemos una fórmula para la distribución *a posteriori*, pero podemos obtenerla muestreando los pesos de la distribución de Dirichlet.

*II-C5. Test bayesiano de Friedman:* El test bayesiano de Friedman [17] realiza un procedimiento similar a los descritos previamente para comprobar si es factible que el parámetro con la media del orden de la clasificación de cada algoritmo se quede en una región cercana al punto medio que constituye la hipótesis nula en un test frecuentista ( $[(m+1)/2, \dots, (m+1)/2]$ ). Si el parámetro de interés  $\mu$  no se encuentra en esta región, existirá una diferencia significativa.

### III. APLICACIÓN *shiny*

Esta sección contiene en la Subsección III-A una descripción de la aplicación *shiny* desarrollada y su base, el paquete *rNPBST* [18]. La Subsección III-B contiene una descripción de la utilización de la aplicación para la comparación de algoritmos, principalmente sobre el uso de los métodos bayesianos, debido a que éstos son menos conocidos y su uso no está extendido.

#### III-A. Paquete *rNPBST*

El paquete *rNPBST* ha sido desarrollado inicialmente como un wrapper de la biblioteca *JavaNPST* desarrollada por Derrac *et al.* [19]. Es una biblioteca en Java que integra un extensivo conjunto de test no paramétricos de diferentes familias y con diferentes propósitos.

En la biblioteca original en Java sólo se incluyen test no paramétricos aunque se han añadido en el paquete de R varios test bayesianos y métodos asociados de visualización a través de *ggplot* y *ggtern* [20]. Los test se clasifican 11 categorías atendiendo al propósito de los test o el tipo de dato usando Tabla I.

El paquete *rNPBST* está disponible en un repositorio de Github<sup>1</sup> y se puede instalar usando el paquete *devtools* y ejecutando en R:

```
devtools::install_github("JacintoCC/rNPBST")
```

#### III-B. Ejemplo de uso

Para la ejecución de la aplicación *shiny* será necesario ejecutar en R la siguiente función del paquete *shiny*:

```
shiny::runGitHub(repo = "shinytests",
                 username = "JacintoCC")
```

<sup>1</sup><http://www.github.com/JacintoCC/rNPBST>

Tabla I: Test incluidos en la versión actual de rNPBST

Family	Test
Test de aleatoriedad	Número de rachas Rachas crecientes y decrecientes Rachas crecientes y decrecientes (Mediana) Von Neumann
Test de bondad del ajuste	Chi-Squared Kolmogorov-Smirnov Lilliefors Anderson-Darling
Una muestra y muestras pareadas	Cuantil de confianza Cuantil de la población Test de signo Test de Wilcoxon de rangos con signo
Procedimientos general de dos muestras	Wald-Wolfowitz Test de medias Control Median Kolmogorov-Smirnov
Problema de escala	David-Barton Freund-Ansari-Bradley Mood Klotz Siegel-Tukey Sukhatme
Problema de posición	Wilcoxon Rank-Sum van der Waerden
Independencia de muestras	Extended Median test Kruskal-Wallis Jonckheere-Terpstra Charkraborti-Desu
Muestras bivariadas	Kendall Daniel Trend
Múltiples clasificadores	Friedman Iman-Davenport Rangos alineados de Friedman Page Coeficiente de concordancia Concordancia incompleta Correlación parcial
Conteo de datos	Coeficiente de contingencia Test exacto de Fisher McNemar Test de igualdad multinomial Ordered Equality test
Bayesianos	t-test bayesiano correlado Test bayesiano de signo Test bayesiano de rangos con signo Test bayesiano de Friedman

Entonces se descargan automáticamente los paquetes necesarios y se abre en el navegador la aplicación. Se incluye la posibilidad de subir un fichero .CSV para realizar los test estadísticos, así como seleccionar distintos test. A medida que vamos realizando cambios en el conjunto de datos introducido, o seleccionando el test a realizar en el menú lateral, se actualizarán automáticamente los resultados. También podremos seleccionar la opción de incluir un gráfico en algunos de los test bayesianos, el cual podremos descargar.

Para ejemplificar el uso de algunos test, presentamos un estudio comparativo entre cinco algoritmos clásicos para problemas de clasificación. Los algoritmos incluidos en la comparación están descritos en la Tabla II. Los resultados de cada algoritmo en los distintos conjuntos de datos se incluyen en el paquete rNPBST y como conjunto por defecto en la aplicación shinytests para poder ejemplificar su uso. La medida usada ha sido la *accuracy*. Se incluye para cada algoritmo descrito en la Tabla II una tabla con los resultados en las particiones 5-dob-cv [21] de algunos de los conjuntos de datos disponibles<sup>2</sup> para clasificación en el repositorio KEEL

<sup>2</sup>abalone, australian, automobile, balance, breast, bupa, car, cleveland, crx, dermatology, german, glass, hayes-roth, heart, ionosphere, led7digit, letter, lymphography, mushroom, optdigits, satimage, spambase, splice, tic-tac-toe, vehicle, vowel, wine, yeast and zoo

Tabla II: Algoritmos comparados en el conjunto de datos de ejemplo

Algoritmo	Descripción	Conjunto de datos
multinom	Regresión logística, del paquete nnet.	results.lr
knn	Biblioteca class. Parám. $k = 1, l = 0$ .	results.knn
randomForest	Biblioteca randomForest. Parám. $mtry = \sqrt{p}$ .	results.rf
nnet	Biblioteca nnet library.	results.nnet
naiveBayes	Clasificador Naive Bayes del paquete e1071.	results.nb

Tabla III: Wilcoxon Rank Sum test

Wilcoxon Rank Sum test		
data.name		results[, 1:2]
statistic		665.00
p.value	Asymptotic Left Tail	0.001565
	Asymptotic Right Tail	0.998512
	Asymptotic Double Tail	0.003129

[22] y en las particiones creadas para ello en este repositorio. Los resultados de las diferentes particiones se resumen usando el promedio en el conjunto de datos results. Se han mantenido por separado los conjuntos para todas las particiones para usarlos en el *t*-test correlado bayesiano.

*III-B1. Análisis de muestras pareadas:* Para una comparación paramétrica entre dos algoritmos podemos usar el test Wilcoxon Rank-Sum. El resultado de aplicar dicho test al conjunto de datos por defecto, seleccionando las dos primeras columnas (correspondientes a la comparación de la regresión logística y el KNN) se incluye en la Tabla III, puesto que en la aplicación shiny se incluye tanto una tabla HTML mostrando los resultados, como el código  $\text{\TeX}$  que produce dicha tabla.

Vemos en la tabla Tabla III que la hipótesis nula  $\mathcal{H}_0 : \mu_{LR} = \mu_{KNN}$  puede rechazarse debido a que el *p*-valor asintótico es menor que 0,05, de manera que este test identifica una diferencia significativa entre estos dos algoritmos. Para determinar cuál obtiene mejores resultados, podemos mirar el *p*-valor para las hipótesis alternativas direccionales y concluimos que la regresión logística obtiene mejores resultados debido a que no podemos rechazar  $\mathcal{H}_i$  cuando la hipótesis alternativa es  $\mathcal{H}_1 : \mu_{LR} > \mu_{KNN}$ .

*III-B2. Test para comparaciones múltiples:* Como se ha descrito en la Sección II, la hipótesis nula del test de Friedman es la equivalencia de las medianas de los diferentes algoritmos, por lo que un *p*-valor menor que un test significa que la hipótesis nula puede ser rechazada y existe una diferencia entre los algoritmos comparados. Se incluye en la Tabla IV los resultados del test de Friedman.

*III-B3. t-test bayesiano correlado:* En este test comparamos los resultados obtenidos por random forest y knn para un único dataset. Con el resultado de este test podemos obtener la Fig. 1 con la diferencia entre estos algoritmos.

Tabla IV: Friedman test

Friedman test		
data.name	s	df
statistic	s	2812.00
	q	39.06
p.value		6.789e-08

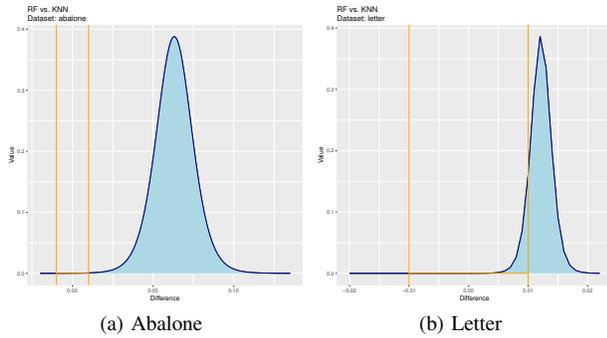


Figura 1: Distribución de RF vs KNN para dos conjuntos de datos

Tabla V: Bayesian correlated t-test

Bayesian correlated t-test		
probabilities for abalone dataset	left	4.962e-05
	rope	4.407e-04
	right	9.995e-01
probabilities for letter dataset	left	1.378e-07
	rope	1.105e-01
	right	8.895e-01
rope		-0.01
		0.01

La distribución *a posteriori* del parámetro de interés muestra cómo con un 99,9% random forest tiene un mejor resultado que knn en este conjunto de datos. La distribución de la diferencia se muestra en Fig. 1 para los conjuntos de datos abalone y letter. En este segundo conjunto de datos, aunque random forest también obtiene un mejor resultado que knn, hay una mayor probabilidad de que ambos algoritmos obtengan el mismo resultado que en el primer conjunto de datos. Para los test bayesianos también obtenemos la Tabla V con los resultados, en este caso es la probabilidad de pertenencia a cada región de interés.

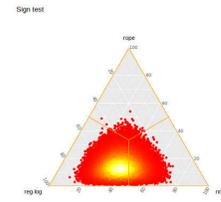
**III-B4. Test bayesiano de signo:** Para este test usamos los resultados promediados de dos algoritmos en todos los conjuntos de datos.

Hay una mayor probabilidad para la hipótesis de que la regresión logística obtenga un resultado mejor que la red neuronal, aunque podemos comprobar que las diferencias son pequeñas en la Tabla VI. En la Fig. 2 se observa una muestra de la distribución *a posteriori* y podemos comprobar cómo hay una mayor concentración de puntos en la región izquierda, que corresponde con la situación en la que la regresión logística obtiene un mejor resultado que la red neuronal. En la Fig. 2b la comparación se realiza entre neural network and random forest. Hay incluso una concentración mayor en la región izquierda, lo que nos dice que hay incluso una mayor probabilidad de que random forest obtenga un mejor resultado que neural network.

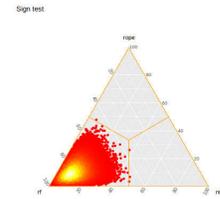
**III-B5. Test bayesiano de rangos con signo:** Repetimos la experimentación usando el test bayesiano de rangos con signo, mostrando la gráfica asociada en la Fig. 3 y los resultados numéricos en la Tabla VII.

Tabla VI: Bayesian Sign-test

test		
probabilities	left	0.4780
	rope	0.1444
	right	0.3777



(a) Red neuronal vs regresión logística



(b) Red neuronal vs random forest

Figura 2: Muestra de la distribución *a posteriori* del test bayesiano de signo

La probabilidad *a posteriori* para la región izquierda es ligeramente mayor que la probabilidad para el test bayesiano de signo, por lo que tenemos una mayor certeza para esta comparación usando el test bayesiano de rangos con signo. Como se puede ver en la Fig. 3, la distribución está desplazada hacia la izquierda, por lo que se espera una mayor potencia de este test con respecto al test bayesiano de signo.

**III-B6. Test bayesiano de Friedman:** En la Tabla VIII se incluye los resultados del test bayesiano de Friedman. En esta tabla se incluyen el orden medio de clasificación para cada algoritmo y la hipótesis seleccionada  $h$ , que en este caso  $h = 1$ , lo que significa que se rechaza que el parámetro pertenezca a la región de igual ranking para todos los algoritmos.

#### IV. CONCLUSIONES

La experimentación inherente a la naturaleza del aprendizaje automático y el rápido crecimiento del número de algoritmos propuestos conlleva la necesidad de establecer un método claro de comparación del desempeño de estos algoritmos y

Tabla VII: Bayesian Signed-Rank test

test		
probabilities	left	0.4921
	rope	0.2220
	right	0.2859

Tabla VIII: Bayesian Friedman test

Bayesian Friedman test					
h	1				
meanranks	3.1	2.433	4.467	2.233	2.767

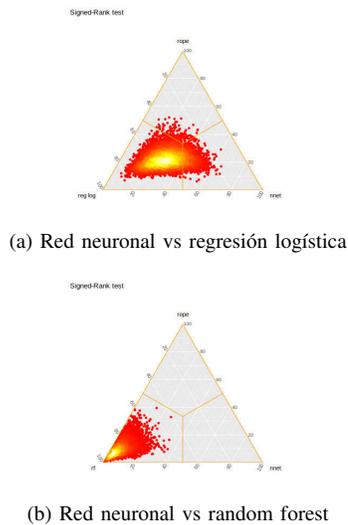


Figura 3: Muestra de la distribución *a posteriori* del test bayesiano de rangos con signo.

una herramienta software que facilite este procedimiento. En esta contribución presentamos la aplicación *shiny* de R, cuyo principal objetivo es proporcionar una herramienta gráfica para los principales test no paramétricos y bayesianos existentes en el paquete *rNPBST*, de manera que se disponga de un software para investigadores interesados en comparar nuevo algoritmos. Como tareas futuras se trabajará en añadir nuevos test a esta aplicación.

#### REFERENCIAS

- [1] N. Japkowicz and M. Shah, eds., *Evaluating Learning Algorithms: A Classification Perspective*. Cambridge University Press, 2011.
- [2] D. J. Sheskin, *Handbook of Parametric and Nonparametric Statistical Procedures*. crc Press, 2003.
- [3] J. M. Bernardo and A. F. Smith, *Bayesian Theory*. IOP Publishing, 2001.
- [4] T. G. Dietterich, "Approximate statistical tests for comparing supervised classification learning algorithms," *Neural computation*, vol. 10, no. 7, pp. 1895–1923, 1998.
- [5] J. Luengo, S. García, and F. Herrera, "A study on the use of statistical tests for experimentation with neural networks: Analysis of parametric test conditions and non-parametric tests," *Expert Systems with Applications*, vol. 36, no. 4, pp. 7798–7808, 2009.
- [6] J. Demšar, "Statistical comparisons of classifiers over multiple data sets," *Journal of Machine learning research*, vol. 7, no. Jan, pp. 1–30, 2006.
- [7] F. Pesarin and L. Salmaso, *Permutation Tests for Complex Data: Theory, Applications and Software*. John Wiley & Sons, 2010.
- [8] E. Kasuya, "Wilcoxon signed-ranks test: Symmetry should be confirmed before the test," *Animal Behaviour*, vol. 79, pp. 765–767, Mar. 2010.
- [9] J. Pizarro, E. Guerrero, and P. L. Galindo, "Multiple comparison procedures applied to model selection," *Neurocomputing*, vol. 48, no. 1, pp. 155–173, 2002.
- [10] S. García and F. Herrera, "An Extension on "Statistical Comparisons of Classifiers over Multiple Data Sets" for all Pairwise Comparisons," *Journal of Machine Learning Research*, vol. 9, no. Dec, pp. 2677–2694, 2008.
- [11] J. Derrac, S. García, D. Molina, and F. Herrera, "A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms," *Swarm and Evolutionary Computation*, vol. 1, no. 1, pp. 3 – 18, 2011.
- [12] A. Benavoli and C. P. de Campos, "Statistical Tests for Joint Analysis of Performance Measures," in *Advanced Methodologies for Bayesian Networks - Second International Workshop, AMBN 2015, Yokohama, Japan, November 16-18, 2015. Proceedings*, pp. 76–92, 2015.
- [13] A. Benavoli, G. Corani, J. Demšar, and M. Zaffalon, "Time for a Change: A Tutorial for Comparing Multiple Classifiers Through Bayesian Analysis," *Journal of Machine Learning Research*, vol. 18, no. 77, pp. 1–36, 2017.
- [14] G. Corani and A. Benavoli, "A Bayesian approach for comparing cross-validated algorithms on multiple data sets," *Machine Learning*, vol. 100, no. 2-3, pp. 285–304, 2015.
- [15] C. Nadeau and Y. Bengio, "Inference for the generalization error," *Machine Learning*, vol. 52, no. 3, pp. 239–281, 2003.
- [16] A. Benavoli, G. Corani, F. Mangili, M. Zaffalon, and F. Ruggeri, "A Bayesian Wilcoxon signed-rank test based on the Dirichlet process," in *Proceedings of the 31th International Conference on Machine Learning, ICML 2014, Beijing, China, 21-26 June 2014*, pp. 1026–1034, 2014.
- [17] A. Benavoli, G. Corani, F. Mangili, and M. Zaffalon, "A Bayesian nonparametric procedure for comparing algorithms," in *Proceedings of the 32nd International Conference on Machine Learning, ICML 2015, Lille, France, 6-11 July 2015*, pp. 1264–1272, 2015.
- [18] J. Carrasco, S. García, M. del Mar Rueda, and F. Herrera, "rNPBST: An R Package Covering Non-parametric and Bayesian Statistical Tests," in *Hybrid Artificial Intelligent Systems: 12th International Conference, HAIS 2017, La Rioja, Spain, June 21-23, 2017, Proceedings* (F. J. Martínez de Pisón, R. Urraca, H. Quintián, and E. Corchado, eds.), pp. 281–292, Cham: Springer International Publishing, 2017.
- [19] J. Derrac, S. García, and F. Herrera, "JavaNPST: Nonparametric Statistical Tests in Java," *ArXiv e-prints*, Jan. 2015.
- [20] N. Hamilton, *Ggtern: An Extension to 'Ggplot2', for the Creation of Ternary Diagrams*. 2018. R package version 2.2.2.
- [21] E. Alpaydin, "Combined  $5 \times 2$  cv F Test for Comparing Supervised Classification Learning Algorithms," *Neural Computation*, vol. 11, pp. 1885–1892, Nov. 1999.
- [22] J. Alcalá, A. Fernández, J. Luengo, J. Derrac, S. García, L. Sánchez, and F. Herrera, "Keel data-mining software tool: Data set repository, integration of algorithms and experimental analysis framework," *Journal of Multiple-Valued Logic and Soft Computing*, vol. 17, no. 2-3, pp. 255–287, 2010.



# Extracción de factores relevantes en el análisis de datos biomédicos: una metodología basada en técnicas de aprendizaje supervisado

Oscar Reyes

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: ogreyes@uco.es

Jose M. Moyano

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: jmoyano@uco.es

Antonio Rivero-Juárez

Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: arjvet@gmail.com

Raúl M. Luque

Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: raul.luque@uco.es

Antonio Rivero

Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: ariveror@gmail.com

Justo Castaño

Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: justo@uco.es

Sebastián Ventura

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: sventura@uco.es

**Resumen**—La determinación del conjunto de variables que se diferencian significativamente entre los grupos de muestras presentes en un estudio biomédico es una tarea que comúnmente se realiza mediante el análisis de cada variable individualmente y/o utilizando técnicas no supervisadas que no tienen en cuenta directamente el criterio de los expertos. En este trabajo se presenta una metodología basada en técnicas de aprendizaje supervisado para guiar el análisis de datos biomédicos, que permite la extracción de subconjuntos de factores relevantes para una correcta clasificación de las muestras en los grupos definidos a priori por los expertos. La metodología propuesta consta de dos fases principales, en la primera se determina la importancia de los factores, mientras que la segunda fase se enfoca en la búsqueda de subconjuntos de factores relevantes mediante la construcción de modelos precisos que logran clasificar correctamente las muestras. La utilidad de la metodología propuesta se ilustra mediante dos casos de estudios reales, mostrando que mediante la aplicación de la misma se podrían detectar relaciones complejas entre los factores, y que favorece el análisis de datos biomédicos que tienen un elevado número de variables descriptoras.

## I. INTRODUCCIÓN

Las técnicas de aprendizaje no supervisado, como el análisis de componentes principales y los algoritmos de clustering, son ampliamente utilizadas en el campo de la bioinformática [1]. Sin embargo, en sentido general este tipo de técnicas no toma en cuenta el criterio de los expertos, que previamente al análisis pudieron haber clasificado las muestras en grupos (cáncer vs sano, tumor maligno vs tumor benigno, etc.), lo que puede implicar una pérdida significativa de información

para la extracción del conocimiento en el análisis de datos biomédicos.

Las técnicas de aprendizaje supervisado, por otro lado, permiten que el conocimiento aportado por los expertos pueda guiar el análisis de los datos, mostrándole a los algoritmos cuáles son las conclusiones (salidas) a las cuales deben llegar. Por ejemplo, un algoritmo de clasificación de imágenes para el diagnóstico del melanoma tratará de aprender las relaciones que vinculan a los datos contenidos en las imágenes con las etiquetas asignadas [2]. De esta manera, los algoritmos de aprendizaje supervisado permiten, dado unos datos de entrada, encontrar una función que produce una salida lo más aproximada posible al conocimiento de los expertos.

Una de las tareas que comúnmente se realiza en el análisis de datos biomédicos es la determinación del conjunto de variables que se diferencian significativamente entre los grupos de muestras definidos por los expertos [3]. Por ejemplo, el *p-value* calculado por el t-test es ampliamente usado como indicador de la relevancia de un factor (en lo adelante se usa el término “factores” para indicar el conjunto de variables que describe las muestras de un problema). Sin embargo, además de que los test paramétricos no deben ser usados en todas las situaciones (este tema se escapa del objetivo de este trabajo), se debe considerar que de esta manera el análisis que se realiza es univariante, desechándose así las relaciones estadísticas que normalmente existen entre los factores de un problema.

Por otro lado, es de destacar que muchos problemas de

biomedicina implican el análisis de un número considerable de factores [4], lo cual hace que la tarea anterior sea inviable de realizar si antes no se han filtrado los factores que son realmente relevantes para el estudio del problema. Ejemplo de esto se encuentra al realizar estudios que involucran el análisis de las expresiones de genes sobre un conjunto de muestras.

En este trabajo se presenta una metodología, la cual está basada en técnicas de aprendizaje supervisado, que permite la extracción de subconjuntos de factores relevantes para una correcta clasificación de las muestras en las clases definidas por los expertos (en lo adelante se usa el término “clase” para indicar la variable que describe la condición por la cual los expertos agrupan las muestras). Esta metodología consta de dos fases principales: (a) la determinación de la importancia de los factores, que permite determinar un ranking de importancia; y (b) la construcción de modelos de clasificación a partir de dicho ranking. El uso de esta metodología puede aportar varios beneficios al análisis de datos biomédicos, ya que no solo se pueden determinar subconjuntos de factores relevantes que influyen en la correcta clasificación de las muestras, sino que los métodos desarrollados también son capaces de detectar distribuciones conjuntas entre factores, e interacciones y dependencias complejas respecto a las clases.

El resto del este trabajo se organiza de la siguiente manera. En la Sección II se describe la metodología, explicando cada una de sus fases. La aplicación de la metodología propuesta se ilustra en la Sección III mediante dos casos de estudio reales, uno relacionado con el diagnóstico de tumores neuroendocrinos pulmonares y el otro con el aclaramiento espontáneo en Hepatitis C. Finalmente, en la Sección IV se presentan las conclusiones del presente trabajo.

## II. METODOLOGÍA

El esquema general de la metodología que se propone se muestra en la Figura 1. El preprocesamiento de los datos es un paso opcional, que no nos detendremos a analizar en profundidad en este trabajo. Sin embargo, hay que destacar que generalmente la calidad de los resultados en el análisis de datos biomédicos depende en gran medida de que se haya hecho un correcto preprocesamiento de los datos [5]. El preprocesamiento de datos abarca una amplia gama de métodos, que van desde la eliminación de outliers y la estimación de valores perdidos hasta el centrado, escalado y transformación de los datos. El uso de cada uno de los métodos de preprocesado debe tener una lógica y justificación correcta, ya que si bien es cierto que un correcto preprocesado de datos puede mejorar significativamente el análisis, también un preprocesamiento incorrecto puede conllevar a la obtención de conclusiones erróneas.

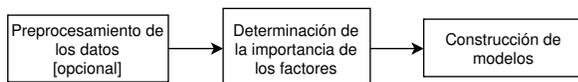


Figura 1. Esquema general de la metodología.

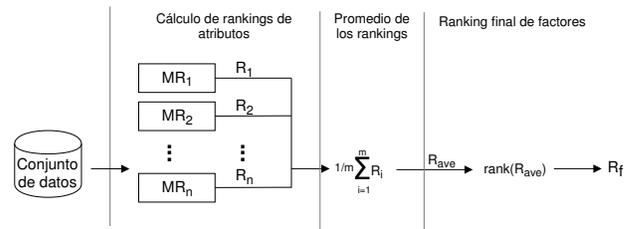


Figura 2. Cálculo del ranking final de factores.

### II-A. Determinación de la importancia de los factores

La primera fase de la metodología se enfoca en la determinación de la importancia de cada uno de los factores del problema, y para ello se propone el uso de algoritmos supervisados de pesado de atributos o *feature weighting* (FW) [6]. La relevancia de un factor se determina mediante la asignación de un peso que representa la información que tiene este para la correcta separación de las muestras en las clases definidas por los expertos [7]. Un método de FW le asigna a cada factor un peso, siendo posible de esta manera obtener un ranking de factores directamente. El objetivo final de esta fase de la metodología es calcular un ranking donde están ordenados de mayor a menor importancia todos los factores.

Digamos que disponemos de  $m$  métodos de FW para lograr una mejor estimación del ranking final de factores.  $R_i$  representa el ranking calculado por el método  $i$ -ésimo,  $R_i(f)$  representa el valor del factor  $f$  en el ranking  $R_i$ , y  $F$  es el conjunto de todos los factores existentes en el estudio. El ranking final de factores se calcula de la siguiente manera:

$$R_f = \text{rank} \left( \frac{1}{m} \sum_{i=1}^m R_i(f) : \forall f \in F \right), \quad (1)$$

donde la función  $\text{rank}(\dots)$  calcula el ranking final de factores a partir de los valores promedios de cada uno de los factores en los  $m$  ranking iniciales. La Figura 2 representa el cálculo del ranking final de factores.

Respecto a la cantidad de métodos de FW a utilizar en la estimación, cuanto mayor sea el número de métodos, más precisa será la estimación del ranking final. En este sentido, se recomienda el uso de métodos supervisados de FW que sean independientes de un clasificador para estimar la importancia de un factor, evitando de esta manera la introducción de sesgos y dependencias en el proceso de estimación. En su lugar se propone el uso de métodos de FW que calculen directamente medidas sobre los datos, como medidas de distancia, entropía o correlación. Estos métodos son conocidos en la literatura especializada como métodos filtros, y entre los más populares podemos encontrar a *Correlation Attribute Evaluation* [8] *Gain Ratio* [9], *Information Gain* [10] y *ReliefF* [11].

Es importante resaltar que para lograr una estimación precisa de la importancia de los factores, es necesario que cada uno de los  $m$  métodos de FW sean ejecutados mediante algún proceso de validación cruzada, el cual dependerá del tamaño del conjunto de datos analizado. Normalmente una validación



cruzada de 10 particiones repetidas varias veces es suficiente para lograr una buena estimación. Sin embargo, en el caso de que el conjunto de datos sea muy pequeño, se deberán considerar otras alternativas para la estimación, como una validación cruzada dejando uno fuera o *Leave One-out Cross Validation* (LOOC).

Por último, es importante destacar que en el ámbito de la biomedicina comúnmente la importancia de un factor se calcula agrupando las muestras por dos o más condiciones y se calcula la diferencia de este factor entre los diferentes grupos; por ejemplo el *p-value* calculado por el t-test es ampliamente usado como indicador de la relevancia de un factor. Sin embargo, además de que los test paramétricos no deben ser usados en todas las situaciones, se debe considerar que de esta manera el análisis que se realiza es univariante, desechándose así las relaciones estadísticas que normalmente existen entre varias variables descriptoras del problema. Esta característica principal es lo que distingue esta primera fase de la metodología propuesta en este trabajo. Los métodos filtros como *ReliefF*, son capaces de detectar distribuciones conjuntas entre variables, interacciones y dependencias complejas respecto a la clase, además de considerar como un todo el conjunto de factores  $F$ .

### II-B. Construcción de modelos

Una vez estimado el ranking de factores, entonces se puede proceder a la determinación de los subconjuntos de factores que mejor logran predecir la clase añadida por los expertos. Sin embargo, esta no es una tarea fácil de realizar, ya que es complejo determinar un punto de corte a partir del cual los factores restantes se pueden considerar como irrelevantes para el análisis.

En lugar de realizar directamente un análisis sobre el ranking de factores  $R_f$ , en esta fase de la metodología se propone una búsqueda heurística guiada para encontrar el mejor subconjunto de factores; el método propuesto está inspirado en el algoritmo presentado por Reyes et al. [12]. En otras palabras, mediante esta fase se podrán determinar aquellos subconjuntos de factores a partir de los cuales se inducen modelos capaces de predecir efectivamente a qué clase pertenece cada muestra. La Figura 3 representa los pasos que sigue el algoritmo diseñado. Como puede observarse, es un proceso iterativo en el que, comenzando con el factor posicionado en el tope del ranking, en cada iteración se analiza si la inclusión del siguiente factor al subconjunto produce un mejor modelo. Finalmente el mejor subconjunto de factores será aquel sobre el cual se induce el mejor clasificador a lo largo de todas las iteraciones.

Para la comparación de la efectividad de los modelos se puede utilizar cualquier medida de evaluación, como el área bajo la curva ROC (AUC, por sus siglas en inglés), ampliamente usada en el análisis de datos biomédicos. Por otro lado, es de destacar que este procedimiento se puede realizar solamente considerando el ranking  $R_f$  o para cada sub-ranking  $R_f^g : \forall g \in R_f$ ; el sub-ranking de factores  $R_f^g$  está compuesto por el factor  $g$  en el tope y todos los subsecuentes factores en  $R_f$ . El

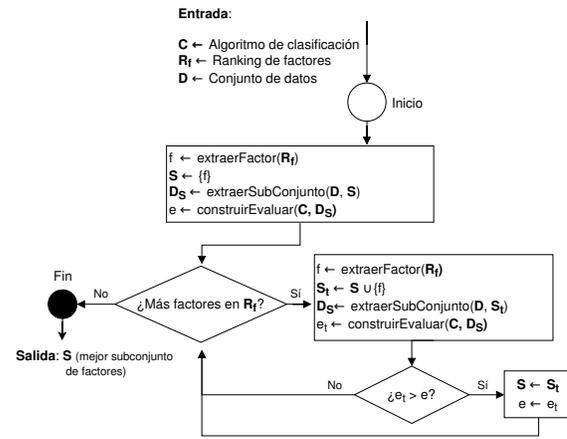


Figura 3. Búsqueda heurística del mejor subconjunto de factores.

primer caso claramente requeriría la construcción de un menor número de clasificadores ( $O(|F|)$ ), mientras que la segunda opción requeriría la construcción de un número cuadrático de clasificadores ( $O(|F|(|F| - 1)/2)$ ); sin embargo, esta última opción es la que produce una mejor estimación. Además, al igual que en la fase anterior, es importante considerar que para lograr una estimación precisa del rendimiento de los clasificadores se debe utilizar un procedimiento de validación cruzada en el proceso de construcción de los mismos.

Respecto al criterio de parada del algoritmo, la Figura 3 ilustra un procedimiento que termina una vez que han sido evaluados todos los factores del ranking. Sin embargo, se pudieran definir otros criterios más flexibles que eviten evaluar completamente el ranking. Por ejemplo, los expertos pueden definir un umbral de aceptación de tal manera que el procedimiento se detenga a penas que se encuentre un modelo con un rendimiento superior a dicho umbral. Por otra parte, los expertos pueden estar interesados en no solo analizar el mejor modelo encontrado, sino los  $n$  mejores modelos construidos.

En esta fase de la metodología se puede utilizar cualquier algoritmo de clasificación para la construcción de los modelos, siempre y cuando este sea adecuado para el análisis. Por ejemplo, se puede usar cualquier algoritmo de clasificación binaria si solo se tienen dos posibles clases para las muestras, o cualquier algoritmo de clasificación multi-clase en caso de que se tengan más de dos clases. Por otra parte, es lógico que el rendimiento obtenido por los modelos dependerá de la efectividad y potencia que tenga el algoritmo de clasificación empleado; por ejemplo, es de esperar que un modelo de ensamblado como *Random Forest* [13] obtenga en promedio mejores resultados que otros modelos más sencillos como *KNN* [10] o *Naive Bayes* [10].

Por último, aclarar que también se pueden utilizar algoritmos de clasificación que tienen un proceso embebido de selección de atributos. En este último caso, es posible que el subconjunto de factores que finalmente utilice el modelo sea más pequeño que el subconjunto original sobre el cual se entrenó el algoritmo.

### III. CASOS DE ESTUDIO

La metodología presentada en este trabajo es utilizada actualmente por varios laboratorios de investigación del Instituto Maimónides de Investigación Biomédica de Córdoba. A continuación se presentan dos casos de estudios reales que muestran la aplicación y utilidad de la propuesta.

#### III-A. Diagnóstico de tumores neuroendocrinos pulmonares

Los tumores neuroendocrinos pulmonares representan entre el 20 y el 30% de todos los tumores neuroendocrinos [14]. La heterogeneidad, sus diferentes comportamientos clínicos, y la posibilidad de aparición recurrente y de hacer metástasis a largo plazo, enfatiza la importancia que tiene la identificación de nuevos marcadores de diagnósticos y terapéuticos, que pueden mejorar el diagnóstico, pronóstico y/o el tratamiento de los pacientes que sufren esta enfermedad [15].

Para este problema, los datos disponibles fueron de 26 muestras pareadas (muestras tumorales con su respectiva muestra de tejido normal adyacente), donde por cada muestra se tenía la expresión de 44 factores que regulan la maquinaria de *splicing*. El objetivo principal del estudio fue determinar subconjuntos de factores que caracterizaran claramente a las dos clases de muestras. En los datos originales no había datos perdidos, y en la etapa de preprocesamiento se eliminaron previamente aquellos factores que tenían varianza igual a cero, y además se centraron y escalaron los datos.

Mediante la primera fase de la metodología propuesta se obtuvo un ranking de factores que permitió determinar cuáles son en promedio los factores más relevantes para diferenciar las clases de muestras. La Figura 4 muestra la importancia de los 20 primeros factores del ranking.

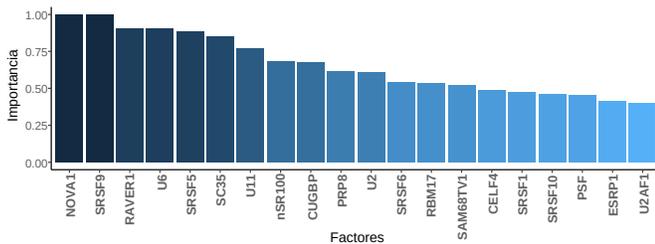


Figura 4. Ranking de factores para diferenciar entre muestras normales y tumorales.

Posteriormente, en la segunda fase de la metodología se utilizaron dos algoritmos de clasificación (*Logistic Regression* (LR) [16] y *Random Forest*) para la evaluación de subconjuntos de factores. Para la estimación de la precisión de los clasificadores se utilizó un procedimiento LOOC debido a que el número de muestras en el estudio era pequeño, y además se realizó una búsqueda *grid* de los mejores parámetros para el entrenamiento de los algoritmos. A partir de este análisis se encontraron 100 modelos con AUC mayor o igual a 0,85, arrojando subconjuntos de factores relevantes que aparecen generalmente en todos los modelos predictivos.

Por otra parte, aunque en la descripción de la metodología (véase Sección II) nos hemos limitado al uso de algoritmos

de clasificación, es de destacar que en la segunda fase del procedimiento se podrían emplear algoritmos de clustering, siempre y cuando los resultados de agrupamiento sean analizados con medidas externas (como la pureza) que tienen en cuenta las clases definidas a priori por los expertos. De esta manera, a los efectos de la metodología el algoritmo de clustering empleado actuaría como si fuera un algoritmo supervisado. En este estudio, los resultados de la segunda fase de la metodología haciendo uso de un algoritmo de clustering jerárquico coinciden con los resultados obtenidos anteriormente por los algoritmos de clasificación, validando así la relevancia de los subconjuntos encontrados. La Figura 5 muestra un *heatmap* con uno de los subconjuntos de factores encontrados.

#### III-B. Aclaramiento espontáneo en Hepatitis C

Una vez que un paciente se infecta por el virus de Hepatitis C (VHC), se produce una hepatitis aguda que en la mayoría de los casos lleva a una infección crónica caracterizada por el avance gradual de fibrosis hepática, cirrosis y carcinoma hepatocelular [17]. Sin embargo, un porcentaje menor de pacientes resuelven su infección de manera espontánea. Por tanto, la identificación de factores o marcadores que ayuden a la predicción del aclaramiento espontáneo (AE) o infección crónica (IC) de VHC tendrían un alto impacto en la selección de la terapia que debería utilizarse para su tratamiento.

Para este problema, los datos disponibles fueron de 138 pacientes infectados con VHC, 81 de ellos con infección crónica y 57 en los que se produjo AE. Cada paciente estaba descrito por 43 marcadores distintos. En 43 muestras habían valores perdidos en algunos de sus marcadores, y se utilizó el algoritmo *knn-Imputation* [18] con  $k = 3$  para estimar dichos valores.

A partir de la primera fase de la metodología, se obtuvo un ranking de factores, del cual en la Figura 6 se muestran los 20 primeros. De esta manera, se puede observar de manera simple la importancia de cada uno de los factores en el problema de VHC. El primer factor en el ranking tiene una importancia cercana a 1, lo que significa que en el proceso de estimación todos los métodos de FW le asignaron en promedio una alta importancia a dicho factor.

Posteriormente, en la segunda fase de la metodología se utilizaron varios clasificadores como *C4.5* [10], *PART* [19], *Random Forest*, *Sparse Discriminant analysis (sparseLDA)* [20] y *Logistic Model Trees (LMT)* [21]. Para la ejecución de cada modelo se repitió 3 veces una validación cruzada en 10 particiones, evaluando en cada caso sobre el conjunto de *test* correspondiente, y promediando así los valores entre un total de 30 ejecuciones. Además, para la búsqueda de los parámetros de los algoritmos se realizó una búsqueda aleatoria de parámetros entre 30 combinaciones distintas.

Para este problema, se obtuvieron en total casi 400 modelos distintos con un AUC > 0,8; donde 126 tenían un AUC > 0,85; y 30 modelos con un AUC > 0,87. Posteriormente, para aquellos modelos con AUC > 0,85 se midió el número de veces que aparece cada uno de los atributos entre dichos

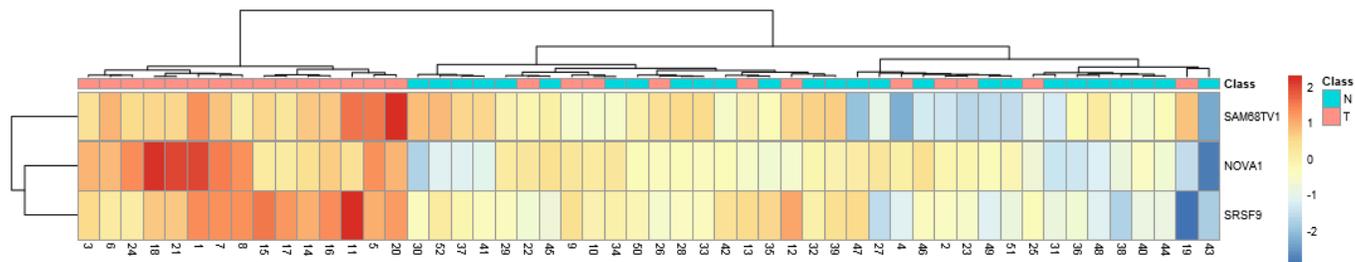


Figura 5. Heatmap generado a partir de un subconjunto de tres factores.

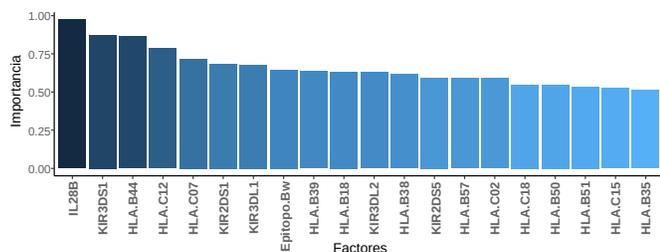


Figura 6. Ranking de factores para el problema de aclaramiento espontáneo en VHC.

modelos. Esta medida proporciona otra aproximación de la importancia de cada uno de los factores en la predicción de la clase, pues un factor que aparezca en un gran número de modelos previsiblemente será más importante en la predicción de la clase que otro factor que aparezca con menor frecuencia.

Por otro lado, el hecho de utilizar modelos de árboles de decisión o reglas de asociación, como *C4.5* o *PART* respectivamente, hace que los modelos resultantes sean fácilmente interpretables por los expertos, pudiendo ver de manera sencilla cómo los factores discriminan para determinar si se predice una u otra clase. En la Figura 7 se muestra un ejemplo de los modelos de árbol obtenidos en el análisis. En la figura se observa como, para un nuevo paciente, dependiendo del valor de cada uno de los factores seleccionados, el modelo descenderá en el árbol hasta predecir la clase a la cual pertenece el paciente (nodo hoja). En estas hojas se puede observar cuál es el porcentaje de pacientes de cada una de las clases que cumplen las condiciones de los factores de los nodos superiores. Por ejemplo, para un paciente donde el factor *IL28B* valga 1 y el factor *HLA.B44* valga 0, el modelo asignará la clase AE, ya que en torno al 70 % de los pacientes observados con esa combinación de factores pertenecen a dicha clase. Cabe destacar también que, como se puede observar, los factores que aparecen en este modelo de árbol se encontraban en las primeras posiciones del ranking obtenido en la primera fase de la metodología, siendo la raíz del árbol precisamente el factor con mayor importancia en el ranking.

Por último, se comparan los resultados de los modelos generados mediante la metodología propuesta con modelos que son construidos considerando todos los factores del problema. La Tabla I muestra los resultados de esta comparación. Para cada

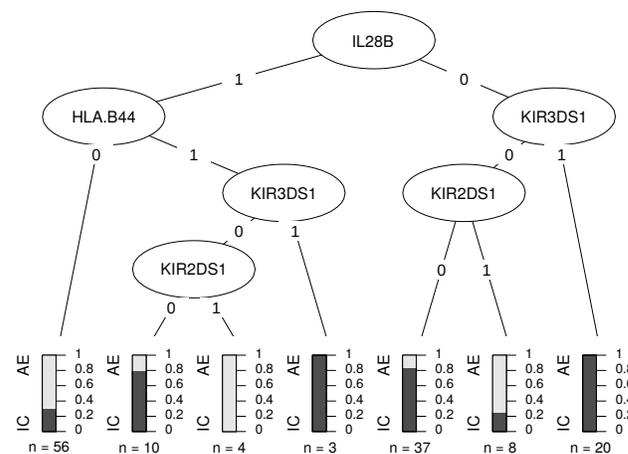


Figura 7. Árbol de decisión generado por uno de los modelos de *C4.5* para el problema de VHC.

Tabla I  
MEJORA DEL RENDIMIENTO PREDICTIVO AL EJECUTAR LOS DISTINTOS ALGORITMOS UTILIZANDO TODOS LOS FACTORES ( $AUC_0$ ) O UN SUBCONJUNTO DE LOS MISMOS DETERMINADOS POR LA METODOLOGÍA PROPUESTA ( $AUC_{SUB}$ ).

Algoritmo	$AUC_0$	$AUC_{sub}$	$f_{sub}$	% mejora
C4.5	0,766	0,842	10	9,92 %
PART	0,742	0,869	11	17,12 %
Random Forest	0,825	0,882	14	6,91 %
sparseLDA	0,839	0,880	8	4,89 %
LMT	0,803	0,872	7	8,59 %

uno de los algoritmos utilizados se muestra el valor de AUC obtenido utilizando los 43 factores del problema ( $AUC_0$ ), y el mejor valor de AUC obtenido generando el modelo con subconjuntos de factores ( $AUC_{sub}$ ); para este último caso, se indica además el número de factores utilizados para la construcción del modelo ( $f_{sub}$ ). En la última columna de la tabla se incluye el porcentaje de mejora en rendimiento predictivo, calculado como  $\frac{AUC_{sub} - AUC_0}{AUC_0}$ . A partir de los resultados se puede observar como mediante la metodología propuesta se pueden obtener mejoras considerables en las predicciones de la clase; por ejemplo en el caso de *PART* se obtiene una mejora de un 17 % considerando solo 11 factores de los 43 existentes.

## IV. CONCLUSIONES

En este trabajo se ha propuesto una metodología para la extracción de factores relevantes en datos biomédicos mediante el uso de técnicas de aprendizaje supervisado. Dicha metodología se divide en dos partes principales, la creación de un ranking de factores que determine la importancia de cada uno de ellos, y la búsqueda de subconjuntos de factores que permitan construir modelos con una alta precisión para predecir el tipo de muestra. Mediante esta metodología es posible detectar relaciones complejas que existen entre los factores que describen a las muestras de un estudio, superando de esta manera el análisis de factores individuales que comúnmente se emplea en biomedicina.

La aplicación de la metodología se ilustró mediante dos casos de estudios reales, mostrando la utilidad y potencial de la misma. En estos problemas, gracias a la metodología propuesta se pudieron identificar subconjuntos de factores relevantes que permiten con una alta precisión clasificar las muestras en las clases definidas a priori por los expertos. Se espera que el uso de la presente metodología se pueda extender a otros grupos de investigación biomédica, facilitando el análisis de datos, así como la creación de biomarcadores para el tratamiento temprano de enfermedades patológicas.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto TIN2017-83445-P del Ministerio de Economía y Competitividad y Fondos FEDER. También ha sido financiado por la ayuda FPU del Ministerio de Educación FPU15/02948.

## REFERENCIAS

- [1] P. Baldi and S. Brunak, *Bioinformatics: the machine learning approach*. MIT press, 2001.
- [2] I. Giotis, N. Molders, S. Land, M. Biehl, M. F. Jonkman, and N. Petkov, “MED-NODE: A computer-assisted melanoma diagnosis system using non-dermoscopic images,” *Expert Systems with Applications*, vol. 42, no. 19, pp. 6578 – 6585, 2015.
- [3] Y. Saeys, I. Inza, and P. Larrañaga, “A review of feature selection techniques in bioinformatics,” *Bioinformatics*, vol. 23, no. 19, pp. 2507–2517, 2007.
- [4] M. Gahete, M. del Rio-Moreno, E. Alors-Perez, O. Reyes, A. Camargo, J. Delgado-Lista, J. Lopez-Miranda, J. P. Castaño, and R. M. Luque, “Identification of an altered spliceosome-associated fingerprint as an early, predictive event for the development of type 2 diabetes in high-risk patients,” in *100th Endocrine Society (ENDO) annual meeting*, 2018.
- [5] R. A. van den Berg, H. C. J. Hoefsloot, J. A. Westerhuis, A. K. Smilde, and M. J. van der Werf, “Centering, scaling, and transformations: improving the biological information content of metabolomics data,” *BMC genomics*, vol. 7, no. 1, p. 142, 2006.
- [6] D. Wettschereck, D. W. Aha, and T. Mohri, “A review and empirical evaluation of feature weighting methods

- for a class of lazy learning algorithms,” *Artificial Intelligence Review*, vol. 11, no. 1-5, pp. 273–314, 1997.
- [7] O. Reyes, C. Morell, and S. Ventura, “Evolutionary feature weighting to improve the performance of multi-label lazy algorithms,” *Integrated Computer-Aided Engineering*, vol. 21, no. 4, pp. 339–354, 2014.
- [8] M. A. Hall, “Correlation-based feature selection for machine learning,” Tech. Rep., 1999.
- [9] S. García, J. Luengo, and F. Herrera, *Data preprocessing in data mining*. Springer, 2016.
- [10] X. Wu, V. Kumar, J. Ross Quinlan, J. Ghosh, Q. Yang, H. Motoda, G. J. McLachlan, A. Ng, B. Liu, P. S. Yu, Z.-H. Zhou, M. Steinbach, D. J. Hand, and D. Steinberg, “Top 10 algorithms in data mining,” *Knowledge and Information Systems*, vol. 14, no. 1, pp. 1–37, 2008.
- [11] M. Robnik-Šikonja and I. Kononenko, “Theoretical and empirical analysis of ReliefF and RReliefF,” *Machine learning*, vol. 53, no. 1-2, pp. 23–69, 2003.
- [12] O. Reyes, C. Morell, and S. Ventura, “Scalable extensions of the ReliefF algorithm for weighting and selecting features on the multi-label learning context,” *Neurocomputing*, vol. 161, pp. 168–182, 2015.
- [13] L. Breiman, “Random forests,” *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [14] A. Fisseler-Eckhoff and M. Demes, “Neuroendocrine tumors of the lung,” *Cancers*, vol. 4, no. 3, pp. 777–798, 2012.
- [15] A. D. Herrera-Martínez, M. D. Gahete, R. Sánchez-Sánchez, R. O. Salas, R. Serrano-Blanch, A. Salvatierra, L. J. Hoffland, R. M. Luque, M. A. Gálvez-Moreno, and J. P. Castaño, “The components of somatostatin and ghrelin systems are altered in neuroendocrine lung carcinoids and associated to clinical-histological features,” *Lung Cancer*, vol. 109, pp. 128–136, 2017.
- [16] S. K. Shevade and S. S. Keerthi, “A simple and efficient algorithm for gene selection using sparse logistic regression,” *Bioinformatics*, vol. 19, no. 17, pp. 2246–2253, 2003.
- [17] M. Frias, A. Rivero-Juárez, D. Rodríguez-Cano, A. Camacho, P. López-López, M. Rialde, B. Manzanares-Martín, T. Brieva, I. Machuca, and A. Rivero, “HLA-B, HLA-C and KIR improve the predictive value of IFNL3 for Hepatitis C spontaneous clearance,” *Scientific Reports*, vol. 8, no. 1, p. 659, 2018.
- [18] L. Torgo, *Data Mining with R, learning with case studies*. Chapman and Hall/CRC, 2010. [Online]. Available: <http://www.dcc.fc.up.pt/~ltorgo/DataMiningWithR>
- [19] E. Frank and I. H. Witten, “Generating accurate rule sets without global optimization,” in *Fifteenth International Conference on Machine Learning*, 1998, pp. 144–151.
- [20] L. Clemmensen, T. Hastie, D. Witten, and B. Ersbøll, “Sparse discriminant analysis,” *Technometrics*, vol. 53, no. 4, pp. 406–413, 2011.
- [21] N. Landwehr, M. Hall, and E. Frank, “Logistic model trees,” *Machine learning*, vol. 59, no. 1-2, pp. 161–205, 2005.



# Aplicaciones de la técnica de *topic model* en repositorios software

Carlos López-Nozal

Área de Lenguajes y Sistemas Informáticos  
Universidad de Burgos  
Burgos, España  
clopezno@ubu.es

César Ignacio García-Osorio

Área de Lenguajes y Sistemas Informáticos  
Universidad de Burgos  
Burgos, España  
cgosorio@ubu.es

Álvar Arnaiz-González

Área de Lenguajes y Sistemas Informáticos  
Universidad de Burgos  
Burgos, España  
alvarag@ubu.es

Mario Juez-Gil

Área de Lenguajes y Sistemas Informáticos  
Universidad de Burgos  
Burgos, España  
mariojg@ubu.es

**Resumen**—Los equipos de desarrollo software usan repositorios de proyectos, accesibles mediante forjas como Github, donde aplican un proceso iterativo e incremental. En el proceso se incluyen actividades como: gestión de tareas, gestión de versiones, codificación, pruebas, documentación, revisiones de calidad y despliegue de aplicaciones. Durante estas actividades se generan múltiples productos a través de complejas interacciones entre sus participantes. La caracterización tanto de productos como de interacciones basadas en texto es un primer paso para comprender y hacer más eficiente la gestión del proyecto. La técnica de aprendizaje textual denominada modelo de temas (*topic model*), mejora la comprensión de grandes cantidades de datos textuales agrupando los documentos en temas. Con el objetivo de poder mejorar las actividades de un proceso de desarrollo software, en este trabajo se presenta una revisión bibliográfica de cómo se está aplicando la técnica de aprendizaje automático y cuáles son los resultados de su aplicación en el contexto del proceso de desarrollo software.

**Index Terms**—Model Topic, Software Repository, Text Mining, Software Development, Machine Learning

## I. INTRODUCCIÓN

En la última década han surgido forjas de proyectos software de fácil acceso tanto para proyectos empresariales como para proyectos *OpenSource* (SourceForge Github, GitLab, Bitbucket). Estas forjas suelen integrar múltiples sistemas para dar soporte a los flujos de trabajo y registrar las interacciones entre los miembros del equipo.

Debido al interés que ha surgido en este campo, la comunidad científica creó en 2004 la Conferencia *Internacional Mining Software Repositories* (MSR <http://www.msrconf.org/>) como un punto de encuentro para analizar los datos disponibles en los repositorios software para descubrir información interesante y procesable sobre sistemas de software y proyectos.

Una de las líneas de trabajo en el aprendizaje automático es el tratamiento de grandes cantidades de documentos basados en texto para poder extraer relaciones entre ellos. El modelado

de temas (*topic model*) es una técnica de agrupamiento de documentos de texto (*clustering*). Cada tema se define siguiendo una distribución de probabilidades de un conjunto de palabras que ocurren con más frecuencia en los documentos de ese tema.

Muchas actividades de los repositorios software llevan implícita una comunicación textual entre los miembros del equipo. Por ejemplo, el análisis de la información textual de las revisiones utilizando la técnica de modelado de temas puede mejorar la comprensión del proceso de calidad.

El objetivo de este trabajo es estudiar en la literatura científica cómo se está aplicando la técnica de modelado de temas, en los conjuntos de datos extraídos desde repositorios software.

El resto del artículo se estructura de la siguiente forma. En la Sec. II, se definen los conceptos teóricos necesarios para la comprensión del artículo. En la Sec. III, se detalla el proceso utilizado para seleccionar la bibliografía a revisar. Posteriormente, en la Sec. IV se resumen los resultados de la revisión bibliográfica. Finalmente, en la Sec. V, se presentan las conclusiones obtenidas del presente trabajo.

## II. DEFINICIÓN DE CONCEPTOS TEÓRICOS

La sección se ha organizado en dos subsecciones, una para los conceptos relacionados con la ingeniería de software y otra para los conceptos relacionados con ciencias de la computación y procesamiento de lenguaje natural.

### II-A. Sistemas utilizados en el desarrollo software

Uno de los resultados del proceso interno de un equipo de desarrollo de software, es crear un conjunto de ficheros de texto que contienen un código que se puede desplegar y ejecutar en algún dispositivo electrónico. El código puede estar escrito en múltiples lenguajes de programación. Para gestionar todo este proceso de creación se usan varios sistemas

de gestión integrados en lo que se denomina repositorio del proyecto. A continuación se da una definición de repositorio de software y se describen alguno de sus sistemas gestión.

- Repositorio software. Los repositorios software son espacios virtuales donde los equipos de desarrollo generan los artefactos colaborativos procedentes de las actividades de un proceso de desarrollo. Los repositorios se alojan en lo que se denominan forjas de proyectos software (*GitHub*, *GitLab*, *SourceForge*, *Bitbucket*) En los repositorios además de guardar los artefactos, versión final y versiones previas, se almacena la interacción de los miembros del equipo justificando el cambio de versión. Dependiendo del artefacto generado se utilizan distintos sistemas: foros de comunicación, sistemas de control de versiones, sistemas de gestión de tareas.
- Sistema de control de versiones. Los *commits* son una de las entidades clave de estos sistemas. Cada cambio de versión de un fichero, o conjunto de ficheros, generado en el repositorio se conoce como *commit*. La evolución del software puede representarse como una secuencia de *commits*. Cada *commit* es creado por un miembro del equipo de desarrollo para registrar un cambio en el software. Además de los detalles de los cambios efectuados en los ficheros, un elemento importante en los *commits* es la información textual que incluye el desarrollador para describir la naturaleza del cambio (mensaje asociado al *commit*). Los repositorios están compuestos por ramas de desarrollo y estas contienen *commits*. Las ramas pueden estar en repositorios centrales, distribuidos en múltiples repositorios locales o remotos. La rama de desarrollo principal es la que mantiene los ficheros actualizados para un versión del software que está en explotación.
- Sistema de gestión de tareas. Cualquier actividad que se va a realizar en un repositorio debería ser notificada con una tarea (el término tarea también es referido como *issue* o *ticket*). De manera general, las actividades en un proceso de desarrollo de software se pueden categorizar en: desarrollo (implementación de nueva funcionalidad), documentación, mantenimiento (pruebas, reestructuración de código, corrección de errores), explotación (despliegue de la aplicación) y revisiones de calidad. Los elementos fundamentales de una tarea son: el texto descriptivo de la tarea, un estado que indica si está abierta o cerrada, opcionalmente puede tener etiquetas que ayuden a su clasificación. Además cada tarea tiene asociado un responsable y también tiene asociado el conjunto de comentarios textuales de los distintos miembros del equipo, desde su apertura hasta su cierre. Cada tarea tiene un identificador que sirve como componente integrador con el resto de sistemas. Por ejemplo el texto descriptivo de un *commit* puede incluir el identificador de la tarea para recoger una trazabilidad de la descripción de los cambios ocasionados por la tarea. Las peticiones de integración (*pull request*) son un tipo de tareas especiales que se crean automáticamente

en el sistema de gestión de tareas cuando un miembro del equipo solicita una integración de sus cambios en la rama de desarrollo principal. Las integraciones pueden ser aceptadas o rechazadas después de un proceso/diálogo de discusión y revisión entre los miembros del equipo.

## II-B. Agrupamiento y procesamiento de documentos

- Modelado de temas o *topic modeling*, es una técnica avanzada de recuperación de información que automáticamente encuentra los temas generales de en un conjunto de documentos de texto, llamado corpus, sin la necesidad de etiquetas, datos de entrenamiento o taxonomías predefinidas. El modelado de temas solo usa la frecuencias de las palabras y la co-ocurrencia de frecuencias en los documentos para construir un modelo de palabras relacionadas. Utilizando este enfoque simple, el modelado de temas se ha utilizado con éxito en múltiples dominios para organizar y analizar automáticamente millones de documentos no estructurados.

En la actualidad existen varios algoritmos que sirven para implementar esta técnica, siendo los más referenciados LDA (Latent Dirichlet Allocation) [4], LSI (Latent Semantic Indexing) y HDP (Hierarchical Dirichlet Process). A continuación formalizamos matemáticamente este concepto. Dado un corpus de documentos  $D = \{d_1, \dots, d_n\}$  donde cada documento  $d_i, i = 1, \dots, n$  es una secuencia de  $m$  palabras denotadas por  $d_i = \{w_1, \dots, w_m\}$ ,  $w_j \in W, j = 1, \dots, m$ .  $W$  es el vocabulario del conjunto de documentos. Cada documento  $d_i$  se puede modelar como una distribución multinomial  $\theta^{d_i}$  sobre  $t$  temas, y cada tema  $z_k, k = 1, \dots, t$  se modela como una distribución multinomial  $\phi^k$  sobre el conjunto de palabras  $W$ .

- Caracterización de documentos de texto. La técnica de modelado de temas necesita caracterizar cada documento  $\{d\}$  con conjunto de valores de entrada  $\{x_1, \dots, x_n\}$ . La bolsa de palabras (*Bag of Words*) es la aproximación más utilizada para representar documentos de texto. En esta representación cada palabra del conjunto de documentos es considerada como una característica  $x_j$ . Existen varios tipos de transformaciones:
  - Boolean: es la más simple de las transformaciones. Si una palabra  $w_j$  está presente en el documento, la característica  $x_j$  toma el valor de 1 y 0 en caso contrario.
  - Raw TF (*Term Frequency*): en esta transformación, la característica  $x_j$  toma como valor el número de ocurrencias de la palabra,  $w_j$ , en el documento  $d_i$  y se referencia como  $f_{i,j}$ . Aunque parece una representación más sofisticada, tiene la desventaja que palabras con poco significado a menudo tienen valores de frecuencias muy altos.
  - Escala logarítmica TF: esta versión de TF se usa para suavizar la desventaja mencionada de la representación Raw TF. Existen varias transformaciones logarítmicas, una de las más usada se calcula aplicando



Cuadro I  
EJEMPLO DE TAREAS DE PROCESAMIENTO DE LENGUAJE NATURAL.

.token	.lemma	.tag	.es_alfabético	.palabra vacía
Updates	update	NOUN	True	False
link	link	VERB	True	False
text	text	NOUN	True	False
and	and	CONJ	True	True
URLs	url	NOUN	True	False
in	in	ADP	True	True
other	other	ADJ	True	True
docs	doc	NOUN	True	False

$\log(1 + f_{i,j})$  para cada palabra  $w_j$  en el documento  $d_i$ .

- **IDF (Inverse Document Frequency):** IDF asigna el valor  $f_{i,j} \log(N/N_j)$ , donde  $N$  es el número total de documentos del corpus, y  $N_j$  es el número de documentos que contienen la palabra. Aplicando esta transformación, una palabra tiene más peso si es infrecuente en el corpus de documentos.
- **TF-IDF:** las transformaciones TF y IDF se multiplican. De esta forma se incrementa el valor de la característica cuando una palabra es frecuente en el documento pero infrecuente en el corpus de documentos.
- **Procesamiento del lenguaje natural.** La extracción de palabras de los documentos se obtiene aplicando una secuencia variable de tareas de procesamiento entre las que se pueden incluir las siguientes: *tokenización*, eliminación de palabras sin significado, selección de términos gramaticales (sustantivo, verbo, adjetivo, adverbio), identificación de secuencias de palabras que se utilizan juntas y lematización.

La *tokenización* es la tarea encargada de dividir un texto en *tokens*. Cada token es una palabra contenida en el texto y está separado con delimitadores, normalmente son espacios en blanco y signos de puntuación. En el lenguaje existen palabras vacías que no aportan significado, como puede ser las preposiciones, artículos, etc. Se suele disponer de una lista de palabras vacías asociadas a cada idioma, generalmente denominada *stop words*. El proceso de identificación sintáctica de las palabras en una frase del documento se denomina etiquetado gramatical (conocido también por su nombre en inglés, *part-of-speech tagging*, *POS tagging* o *POST*). El lematizado es una forma de normalización de la palabra, reduce una palabra a su forma base, raíz o lema.

En el Cuadro I se muestra un ejemplo ilustrativo de los resultados de aplicar las tareas de procesamiento de texto: tokenización, identificación de palabras vacías, etiquetado gramatical y lematización. El ejemplo es aplicado para procesar la siguiente entrada de texto “*Updates link text and URLs in other docs*”. Las columnas se corresponden con las salidas de las tareas del preproceso (token, lema, tag, stop, es alfabético) y las filas son tokens de la frase de entrada.

### III. PROCESO DE SELECCIÓN DE ARTÍCULOS

En esta sección se describe cuál ha sido el proceso de búsqueda y selección de artículos que sirvan para comprender cómo se está utilizando la técnica de modelado de temas en los repositorios software.

Se utiliza la base de datos Scopus para seleccionar los documentos de interés a revisar. Inicialmente la búsqueda con la palabra clave “GitHub”, se hace en el título, resúmenes y palabras clave de los artículos. El número de artículos encontrados con este criterio de búsqueda fue de 3,697. En la siguiente iteración de búsqueda se incluye en la cadena de búsqueda “LDA” (*Latent Dirichlet Allocation*), por ser las siglas del algoritmo de modelado de temas más utilizado. Con este refinamiento del criterio de búsqueda, el número de documentos fue de 18. Posteriormente se refina la búsqueda incluyendo otros repositorios de proyectos y otros algoritmos de modelado de tópicos. Finalmente se obtienen 30 artículos siendo las principales áreas de conocimiento *Computer Science* (24) y *Mathematics* (5).

Como última etapa del proceso de la búsqueda sistemática, se realizó una lectura de los resúmenes y palabras clave para poder verificar la validez del artículo respecto a los criterios de búsqueda. En esa inspección se encontraron varios falsos positivos, por un lado debido a la aparición de la palabra reservada Github como url utilizada para distribuir una determinada implementación de software en un repositorio. Por otro lado, por el uso del término “Lda” en la sentencia “*Science and Technology Publications, Lda*”. Como resultado se obtuvieron ocho artículos, dos de revistas y seis de actas de congresos internacionales.

Además de este proceso de búsqueda sistemática, se realizó una búsqueda no sistemática utilizando múltiples criterios con términos relacionados: *machine learning*, *text mining*, *text clustering*, *mining software repositories*, ... Como resultado de este proceso se incluyeron tres artículos más de revistas.

El Cuadro II contiene una descripción de las referencias bibliográficas de estudio ordenadas por método de búsqueda (sistemático vs. no sistemático) y después por año de publicación.

### IV. REVISIÓN BIBLIOGRÁFICA

Para facilitar la comprensión de esta revisión, en las siguientes subsecciones caracterizamos todos los trabajos seleccionados desde tres perspectivas: descripción del conjunto de datos que utilizan, aplicación del modelo de temas, técnicas de procesamiento del lenguaje natural.

#### IV-A. Descripción de los conjuntos de datos

En el Cuadro III se muestran los resultados de la caracterización para los que se han considerado las siguientes cinco características:

- **CD1 Tipo de entidades,** es un medida nominal que identifica los elementos de análisis dentro del repositorio software. Puede tomar los siguientes valores: *pull request*, *commit*, *source code*, *fichero Readme*, *issue*, *post*. En la Subsec. II-A se han explicado *pull request*,

Cuadro II  
ARTÍCULOS SELECCIONADOS PARA LA REVISIÓN

Título	Tipo	Año	Referencia
What are developers talking about? An analysis of topics and trends in Stack Overflow	Revista	2014	[3]
Open source is a continual bugfixing by a few	Actas congreso	2014	[5]
An insight into the pull requests of GitHub	Actas congreso	2014	[12]
Mining source code topics through topic model and words embedding	Actas congreso	2016	[17]
Topic-Based Integrator Matching for Pull Request	Actas congreso	2017	[8]
Cataloging GitHub repositories	Actas congreso	2017	[13]
Developer Identity Linkage and Behavior Mining Across GitHub and StackOverflow	Revista	2017	[15]
Mining developer behavior across git hub and stack overflow	Actas congreso	2017	[16]
Mining software repositories for defect categorization	Revista	2015	[7]
MSR4SM: Using topic models to effectively mining software repositories for software maintenance tasks	Revista	2015	[14]
Understanding Review Expertise of Developers: A Reviewer Recommendation Approach Based on Latent Dirichlet Allocation	Revista	2018	[6]

Cuadro III  
RESUMEN DE LAS CARACTERÍSTICAS DE LOS CONJUNTOS DE DATOS  
EXPERIMENTALES DE LA BIBLIOGRAFÍA.

BIB	CD1	CD2	CD3	CD4	CD5
[3]	post	3.447.987	7 meses actividad	SI	StackOverFlow
[5]	commits, issues	NO	43	NO	2014 MSR Challenge
[12]	pull request	9.421	78	NO	2014 MSR Challenge
[17]	source code	NO	100	SI	2013 MSR Challenge
[8]	pull request	4.364	3	NO	GitHub
[13]	fichero Readme	10.000	10.000	SI	GitHub
[16]	issue y post	16.000	No especificado	SI	GitHub StackOverFlow
[7]	Issue-bug	2.500	4	NO	OpenSource
[14]	post, commit, bugs	NO	3	NO	OpenSource
[6]	pull request	1.345	5	NO	GitHub

*commit*, *source code* e *issue*. Por *post* se entiende el mensaje y respuestas enviadas por los desarrolladores en un foro de tipo pregunta respuesta, como *StackOverFlow*. Los ficheros *Readme* de los repositorios de GitHub, son ficheros de texto que sirven para describir el contenido del repositorio, son una página de presentación del repositorio.

- CD2 Número de entidades o documentos de texto en la validación empírica del algoritmo de modelado de temas.
- CD3 Número de repositorios incluidos en el diseño experimental.
- CD4 Uso de entidades de múltiples repositorios es una medida booleana. En el caso de ser cierta, indica que en el diseño experimental utiliza las entidades de múltiples repositorios mezcladas entre sí. En [3] toma el valor de cierto, porque extrae los temas asociados a los post de la plataforma StackOverFlow durante un periodo de siete meses de actividad. En [17] se agrupan por temas ficheros fuentes de múltiples repositorios y en [13] se analizan los ficheros *Readme* de múltiples repositorios para extraer sus temas automáticamente.
- CD5 Disponibilidad de acceso a los conjuntos de datos utilizados en el validación empírica es una medida nominal. Github y StackoverFlow indican que en los trabajos se utilizada un API (*Application Program Interface*) pública para acceder a datos de estos repositorios. *MSR Challenge (Mining Software Repositories)* son los conjuntos de datos utilizados para una sesión de desafío del conferencia internacional MSR. *OpenSource* se ha utilizado para categorizar los trabajos con información de repositorios de tipo *OpenSource*.

#### IV-B. Aplicación del modelo de tópicos

En la Tabla IV se muestran los resultados de la caracterización para los que se han considerado las siguientes seis características:

- AMT1 Algoritmo es una medida nominal con el nombre del algoritmo de modelado de temas. En la bibliografía existe varias implementaciones distintas del algoritmo LDA, se han identificado con un número, 1 para la implementación conocida como MALLETT (<http://mallet.cs.umass.edu/>) y 2 para la implementación conocida como JGIBBLDA (<http://jgibbllda.sourceforge.net/>). LDA-GA indica una combinación del uso de LDA con algoritmos genéticos (*Genetic Algorithms*) para la optimización de sus parámetros en un conjunto de datos concreto. EmbTE *Embedded Topic Extraction*, se corresponde con la solución particular presentada [17], al igual que SDCL *Software Defect CLustering* es la propuesta de solución en [7].
- AMT2 Iteraciones es un parámetro del algoritmo que sirve para determinar la condición de parada del algoritmo y convergencia de los resultados. Es un parámetro opcional.
- AMT3 Número de tópicos/temas es un parámetro necesario por el algoritmo LDA.
- AMT4 Etiquetado manual es una medida booleana. En el caso de ser cierta indica que los temas, probabilidades de conjuntos de palabras, obtenidos como salida del algoritmo son verificados manualmente por una persona. El objetivo de la verificación es mejorar la comprensión humana asignando una única palabra clave al conjunto palabras obtenidas con el algoritmo. Por ejemplo en el etiquetado manual de [3] se asigna “SQL” como palabra clave del tema cuyas cuatro palabras más probables son “quer”, “table”, “sql” y “row”. El proceso de etiquetado manual, implica determinar el número de palabras con las que establecer la palabra clave (por ejemplo en [12] usan 4). Además, hay que tomar decisiones sobre cuáles de los temas obtenidos como salida del algoritmo son coherentes. En [13] durante las inspecciones : *i*) asignan una etiqueta a un tema, *ii*) eliminan un tema por no ser coherente y *iii*) fusionan varios temas en uno.
- AMT5 Validación es una medida booleana que indica si en el diseño experimental se incluye alguna calibración



Cuadro IV  
RESUMEN DE LAS CARACTERÍSTICAS DE LA APLICACIÓN DEL  
ALGORITMO DE MODELADO DE LA BIBLIOGRAFÍA.

BIB	AMT1	AMT2	AMT3	AMT4	AMT5	AMT6
[3]	LDA1	500	40	SI	NO	NO
[5]	LDA1	1000	50	NO	NO	NO
[12]	LDA2	3000	100	SI	NO	NO
[17]	LDA,EmbTE		NO	NO	SI	IDF -TF y TF
[8]	LDA2	1000	15	NO		NO
[13]	LDAGA	500	49	SI	SI	IDF-TF
[16]	LDA	NO	NO	NO	NO	NO
[7]	SDCL			NO		IDF-TF
[14]	LDAGA	NO	NO	NO	SI	NO
[6]	LDA1	NO	20	NO	NO	NO

de los parámetros del algoritmo. Por ejemplo en [13] se utilizan medidas de coherencia de los temas obtenidos con LDA para determinar el parámetro de número de tópicos óptimo. La utilización de algoritmos genéticos para la optimización de parámetros de LDA es una solución presentada en varios trabajos [13], [14].

- AMT6 Transformación del corpus es una medida nominal que indica la representación numérica del conjunto de documentos. Es uno de los parámetros de entradas obligatorios del algoritmo ya que no puede configurarse con un valor por defecto. Los posibles valores son los presentados en Subsc. II-B: TF, IDF-TF.

#### IV-C. Técnicas de procesamiento del lenguaje natural

En la Tabla V se muestran los resultados de la caracterización para los que se han considerado las siguientes seis características:

- TP1 Tokenización es una medida ordinal que puede tomar los valores BAJO, MEDIO y ALTO. BAJO hace referencia cuando el proceso de división de textos en palabras se basa únicamente en utilizar espacios en blanco y signos de puntuación como separadores. MEDIO cuando utiliza un sistema de tokenización especial relacionado con el tipo de documento. AVANZADO cuando realiza múltiples sistemas de tokenización especiales. Para aclarar el concepto de sistema de tokenización especial se presentan algunos casos concretos. En [13] se elimina texto de cabeceras de los ficheros *Readme* para quedarse sólo con aspectos funcionales, se eliminan texto relacionados con licencias, instalación... Cuando los documentos a tratar contienen código de programación, como en [6] y [17], se realiza un tipo de procesamiento especial denominado *camel case splitting* para dividir identificadores de las entidades de código que están compuestos por varias palabras, por ejemplo “*nameToIndex*”, “*loanInterest*” o “*hasDupdName*”. En [14] se eliminan identificadores de usuario dentro del cuerpo de los documentos, típicamente precedidos por el símbolo @.
- TP2 Palabras vacías es una medida booleana para indicar que se ha incluido esta tarea en el procesamiento del lenguaje. En [17] y en [6] se añaden las palabras que for-

Cuadro V  
RESUMEN DE LAS CARACTERÍSTICAS DE LA APLICACIÓN DEL  
ALGORITMO DE MODELADO DE LA BIBLIOGRAFÍA.

BIB	TP1	TP2	TP3	TP4	TP5	TP6
[3]	ALTO	SI	SI	NO	NO	2-grams
[5]	MEDIO	SI	NO	SI	NO	NO
[12]	BAJO	SI	SI	NO	NO	NO
[17]	MEDIO	SI	SI	SI	SI	NO
[8]	BAJO	SI	SI	NO	NO	NO
[13]	ALTO	SI	SI	NO	NO	NO
[16]	BAJO	SI	SI	SI	NO	NO
[7]	BAJO	SI	SI	NO	NO	NO
[14]	MEDIO	SI	NO	NO	NO	NO
[6]	MEDIO	SI	SI	NO	NO	NO

man parte del lenguaje de programación (*if*, *implements*, *class*...).

- TP3 Lematización es una medida booleana para indicar que se ha incluido la tarea en el procesamiento del lenguaje. El tipo de algoritmo empleado mayoritariamente es el de Porter.
- TP4 Filtrado de palabras en el corpus es una medida booleana para indicar que se ha incluido esta tarea en el procesamiento del lenguaje. Los valores umbrales de las frecuencia de palabras en el corpus añaden poca información relevante para categorizar. En [5] se eliminan cadenas de palabras muy frecuentes en el texto de las *issues*: “*good job*”, “*thank you*”. En [17] elimina palabras muy frecuentes en los identificadores de entidades de programación como por ejemplo “*set*”. En [15] se aplica una estrategia más general eliminando todas las palabras que tienen una frecuencia inferior a 20 en el conjunto de documentos.
- TP5 Etiquetado sintáctico es una medida booleana para indicar que se ha incluido esta tarea en el procesamiento del lenguaje. Además del etiquetado de lenguaje natural explicado en Subsec. II-B se considera etiquetado sintáctico la identificación de entidades de código: clase, método, parámetro, etc. que se aplica en [17] sobre los documentos de texto basados en código fuente.
- TP6 Identificación de secuencia de palabras que se usan juntas es una medida booleana para indicar que se ha incluido esta tarea en el procesamiento del lenguaje. En [3] se muestra el siguiente ejemplo de aplicación de esta técnica “*compile time error*”, tiene tres uni-grams “*compile*”, “*time*”, “*error*” y 2-grams (“*compile\_time*”, “*time\_error*”). Para aplicar esta técnica configura un parámetro de la implementación MALLET del algoritmo LDA, llamado *gram-size*.

## V. CONCLUSIONES

En la actualidad, empieza a existir un interés en aplicar la técnica de modelado de temas en las actividades de los sistemas de los repositorios software. Su objetivo es mejorar las tareas de mantenimiento del software caracterizando las entidades de interacción textual. Esta observación está basada en que la búsqueda sistemática de bibliografía ha localizado diversos artículos comprendidos entre las fechas 2014 y 2018.

En la revisión bibliográfica, la aplicación del modelado de temas ha sido motivada por diferentes causas. Una de ellas ha sido la aplicación de manera directa sobre alguna entidad textual de los repositorios, con el objetivo de mejorar la comprensión. Otra motivación es utilizar las salidas del algoritmo de modelado de temas como entrada de otras técnicas de aprendizaje automático.

Respecto a la caracterización de los conjuntos de datos experimentales del Cuadro III, se observa que el modelado de temas se aplica sobre múltiples entidades de los repositorios (CD2), y que el número de entidades varía mucho, desde 3,447,987 hasta 1,345. Los valores altos de CD2 se corresponden con trabajos donde se aplica el modelado de temas con entidades de múltiples repositorios (CD4). Esta correlación también ocurre con el número de repositorios (CD3, CD4). Algunos de los trabajos que realizan diseños experimentales aplicando LDA sobre un único repositorio, eliminan inicialmente algunos repositorios por falta de número de entidades y de contenido textual para experimentar. El acceso a los conjuntos de datos es abierto, pero necesitan eliminar ruido para mejorar la experimentación. Una carencia importante observada es que no hay ningún trabajo que experimente sobre datos de empresa que no procedan de proyectos *OpenSource*.

Respecto a la caracterización de cómo se aplica el algoritmo de modelado de temas del Cuadro IV, se observa que LDA es un algoritmo de referencia en el modelado de temas, pero la configuración de sus parámetros varía entre experimentos. Este es el caso del número de iteraciones (AMT2) y número de temas (AMT3). Además, otros parámetros rara vez se incluyen en el artículos, este es el caso de la transformación del corpus utilizada (AMT6). La transformación del corpus predominante en los trabajos es IDF-TF. En el 30 % de los trabajos, la salida de LDA es supervisada por una persona para garantizar la coherencia de los temas obtenidos. Solo el 30 % de los trabajos validan empíricamente que los parámetros elegidos para la ejecución del algoritmo tiene un desempeño óptimo (AMT5). Una tendencia actual es validar estos parámetros utilizando algoritmos genéticos sobre diferentes ejecuciones del algoritmo con distintos parámetros. En este sentido en la bibliografía se han identificado dos nuevas fuentes bibliográficas [11] y [1] que detallan como calibrar los parámetros de LDA.

Respecto a la caracterización de técnicas del lenguaje natural recogidas en el Cuadro V, se observa que las técnicas clásicas de eliminación de palabras vacías (TP1) y lematización (TP3) con el algoritmo de Porter son especificadas en el 100 % de los trabajos. Otras técnicas documentadas que mejoran la calidad de la representación del documentos como: filtrado de términos por frecuencia en el corpus documentos (TP4), análisis de elementos sintácticos (TP5) e identificación de secuencia de palabras (TP6) son aplicadas en el 30 % de los artículos, 10 % y 10 % respectivamente.

Como conclusión final se considera que el modelado de temas aplicado a tareas de mantenimiento del software tiene una proyección prometedora, pero su aplicación necesita madurar. En este sentido, en los artículos revisados no se ha encontrado la documentación experimental necesaria que

facilite el replicado del experimento, es decir, repositorios *OpenSource* con conjuntos de datos y los programas para comparar y mejorar los diseños experimentales.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto TIN2015-67534-P (MINECO/FEDER, UE) del Ministerio de Economía y Competitividad del Gobierno de España y por el proyecto BU085P17 (JCyL/FEDER, UE) de la Junta de Castilla y León ambos cofinanciados con los fondos FEDER de la Unión Europea.

Un especial agradecimiento a la Doctora Yulan He de la Aston University por acogernos en sus seminarios y enseñarnos técnicas sobre procesamiento del lenguaje natural y aprendizaje automático basado en texto.

#### REFERENCIAS

- [1] Amritanshu Agrawal, Wei Fu, and Tim Menzies. What is wrong with topic modeling? and how to fix it using search-based software engineering. *Information and Software Technology*, 98:74–88, jun 2018.
- [2] H. U. Asuncion, A. U. Asuncion, and R. N. Taylor. Software traceability with topic modeling. volume 1, pages 95–104, 2010.
- [3] A. Barua, S.W. Thomas, and A.E. Hassan. What are developers talking about? an analysis of topics and trends in stack overflow. *Empirical Software Engineering*, 19(3):619–654, 2014.
- [4] D.M. Blei, A.Y. Ng, and M.I. Jordan. Latent dirichlet allocation. *Journal of Machine Learning Research*, 3(4-5):993–1022, 2003.
- [5] M. Fejzer, M. Wojtyna, M. Burzańska, P. Wiśniewski, and K. Stencel. Open source is a continual bugfixing by a few. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8716:153–162, 2014.
- [6] Jungil Kim and Eunjoon Lee. Understanding review expertise of developers: A reviewer recommendation approach based on latent dirichlet allocation. *Symmetry*, 10(4), 2018.
- [7] S. Kumaresh and R. Baskaran. Mining software repositories for defect categorization. *Journal of Communications Software and Systems*, 11(1):31–36, 2015.
- [8] Z. Liao, Y. Li, D. He, J. Wu, Y. Zhang, and X. Fan. Topic-based integrator matching for pull request. volume 2018-January, pages 1–6, 2018.
- [9] S. K. Lukins, N. A. Kraft, and L. H. Etzkorn. Bug localization using latent dirichlet allocation. *Information and Software Technology*, 52(9):972–990, 2010.
- [10] G. Maskeri, S. Sarkar, and K. Heafield. Mining business topics in source code using latent dirichlet allocation. pages 113–120, 2008.
- [11] Annibale Panichella, Bogdan Dit, Rocco Oliveto, Massimiliano Di Penta, Denys Poshyanyk, and Andrea De Lucia. How to effectively use topic models for software engineering tasks? an approach based on genetic algorithms. In *2013 35th International Conference on Software Engineering (ICSE)*. IEEE, may 2013.
- [12] M.M. Rahman and C.K. Roy. An insight into the pull requests of github. pages 364–367, 2014.
- [13] A. Sharma, F. Thung, P.S. Kochhar, A. Sulistya, and D. Lo. Cataloging github repositories. volume Part F128635, pages 314–319, 2017.
- [14] X. Sun, B. Li, H. Leung, B. Li, and Y. Li. Msr4sm: Using topic models to effectively mining software repositories for software maintenance tasks. *Information and Software Technology*, 66:1–12, 2015.
- [15] Y. Xiong, Z. Meng, B. Shen, and W. Yin. Developer identity linkage and behavior mining across github and stackoverflow. *International Journal of Software Engineering and Knowledge Engineering*, 27(9-10):1409–1425, 2017.
- [16] Y. Xiong, Z. Meng, B. Shen, and W. Yin. Mining developer behavior across git hub and stack overflow. pages 578–583, 2017.
- [17] W.E. Zhang, Q.Z. Sheng, E. Abebe, M. Ali Babar, and A. Zhou. Mining source code topics through topic model and words embedding. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10086 LNAI:664–676, 2016.

**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 5:  
PREPROCESAMIENTO DE DATOS







# Feature Dimensionality vs. Distribution of Sample Types: A Preliminary Study on Gene-Expression Microarrays

J. Salvador Sánchez

*Institute of New Imaging Technologies*  
*Department of Computer Languages and Systems*  
*Universitat Jaume I*  
Castelló de la Plana, Spain  
sanchez@uji.es

Vicente García

*División Multidisciplinaria de Ciudad Universitaria*  
*Universidad Autónoma de Ciudad Juárez*  
Ciudad Juárez, Chihuahua, Mexico  
vicente.jimenez@uacj.mx

**Abstract**—In gene-expression microarray data sets each sample is defined by hundreds or thousands of measurements. High-dimensionality data spaces have been reported as a significant obstacle to apply machine learning algorithms, owing to the associated phenomenon called ‘curse of dimensionality’. The analysis and interpretation of these data sets have been defined as a very challenging problem. The hypothesis proposed in this paper is that there may exist some correlation between dimensionality and the types of samples (safe, borderline, rare and outlier). To examine our hypothesis, we have carried out a series of experiments over four gene-expression microarray databases because these data correspond to a typical example of the so-called ‘curse of dimensionality’ phenomenon. The results show that there indeed exist meaningful relationships between dimensionality and the proportion of each type of samples, demonstrating that the amount of safe samples increases and the total number of borderline samples decreases as dimensionality of the feature space decreases.

**Index Terms**—Gene-expression microarray, feature dimensionality, sample types, feature ranking, classification

## I. INTRODUCTION

The ‘curse of dimensionality’ phenomenon (also known as the Hughes phenomenon) constitutes a challenging problem in many real-life applications. It refers to a situation in which the number of samples needed to estimate an arbitrary function with a given level of accuracy grows exponentially with respect to the number of input variables (dimensionality) of the function [1]. An illustrative example of this problem corresponds to gene-expression microarray data [2], [3] where the number of genes ( $G$ ) massively exceeds the sample size ( $n$ ): there are typically over tens of thousands of gene-expression levels and often less than 100 samples in the data set. This is a problem in itself because it may increase the complexity of classification/prediction, degrade the generalization ability of classifiers and hinder the understanding of the underlying relationships between the genes and the samples [4], [5]. Besides, overfitting is also a major issue in a high-dimensional, low-sample scenario [6].

Feature selection is the standard way to tackle this problem by choosing a subset of informative variables from the whole

set of features for further analysis. In the specific context of microarray data, there exists an apparent need for dimensionality reduction not only because of the huge number of input variables, but also because many of them can be highly correlated with other variables. Throughout the last decades, many different feature (gene) selection algorithms have been proposed using filter, wrapper, embedded, ensembles and hybrid methods [7]–[11].

A particularly popular strategy for feature selection over microarray data refers to the use of gene ranking algorithms, which are filters that comprise some univariate scoring metric to quantify how much more statistically significant each gene is than the others [12]. These methods rank genes in decreasing order of the estimated scores under the assumption that the top-ranked genes correspond to the most informative (or differentially expressed) ones across different classes without redundancy.

The central question the present study intends to answer is how dimensionality of the feature space and some intrinsic data characteristics are related to each other. More specifically, this paper examines whether or not dimensionality reduction may alter the distribution of the different types of samples defined by several authors [13], [14]. To gain some insight into this question, we analyze the tendency of the amount of each type of samples when varying the dimensionality of the feature space. For the experiments, we consider four public data sets of gene-expression microarrays.

Over the past years, the potential links between feature dimensionality and several data complexities in microarrays have been a matter of concern for researchers. For instance, Baumgartner and Somorjai [15] used five real-life biomedical databases of increasing difficulty to show how the data complexity of a given classification problem can be related to the performance of regularized linear classifiers. Okun and Primalu [16] explored the connections between data complexity and classification performance defined by low-variance and low-biased bolstered resubstitution error made by  $k$ -nearest neighbor classifiers. Souto et al. [17] computed different

measures characterizing the complexity of gene expression data sets for cancer diagnosis, and then investigated how those measures were related to the classification performances of support vector machines. Bolón-Canedo et al. [18] presented a review of a set of feature selection methods applied to DNA microarray data and analyzed the impact of class imbalance, class overlapping or data set shift on the classification results. Similarly, Sánchez and García [19] demonstrated that there exist meaningful relationships between dimensionality and class separability in gene-expression microarray data sets. Lorena et al. [20] studied the complexity of several microarray data sets with and without dimensionality reduction using a support vector machine. Seijo-Pardo et al. [21] proposed the use of three data complexity measures to automatically set a threshold value, which is then employed to obtain a subset of genes from the ordered ranking given by a ranker algorithm. Morán-Fernández et al. [22] demonstrated that there is some correlation between microarray data complexity and the classification error rates of a set of classifiers. Sun et al [23] proposed an ECOC algorithm to address the small sample size and class imbalance problems in multi-class microarray data sets by exploring data distributions based on data complexity theory.

Henceforth, the rest of the paper is organized as follows. Section II presents the types of samples according to the taxonomy proposed by Napierala and Stefanowski [14]. Section III provides the experimental set-up and the description of the databases used in our experiments. Next, the results are reported and discussed in Section IV. Finally, Section V summarizes the main conclusions and points out some directions for future research.

## II. TYPES OF SAMPLES

Following the categorization proposed by several authors [13], [14], [24], two main types of samples should be distinguished: *safe* and *unsafe*. Safe samples refer to those located in homogeneous regions with data of a single class and are sufficiently separated from examples of other classes, whereas the rest of samples have to be considered as unsafe. The safe samples will be classified correctly by most models, but the classification of unsafe samples will usually be a very tricky task with a high error rate.

The general feature of unsafe samples is that they are placed close to examples from some other classes. However, this type of data can be further divided into three subgroups depending on their particular characteristics [14], [25]: *borderline*, *rare* and *outlier*. Borderline samples are located near the decision boundaries between classes. Rare samples are small groups of examples located far from the core of their class, creating small data chunks or subclusters. Finally, the outliers are single samples being surrounded by examples that belong to some other class.

A simple method to identify each type of samples is based on analyzing the local neighborhood of the examples. This can be performed either by searching for the  $k$  neighbors of a sample or by using some kernel function. Thus, one can guess

that a safe sample  $x$  will be characterized by having a neighborhood with a majority of examples that belong to its same class; rare examples and outliers will be mainly surrounded by examples from different classes, whereas borderline samples will be surrounded by examples both from their same class and also from different classes.

Many authors often choose  $k = 5$  because smaller values may poorly distinguish the nature of samples, while higher values would violate the assumption of the local neighborhood [14], [24]–[26]. Following this procedure, we can define the following cases:

- A sample  $x$  will be classified in the safe category if at least 4 out of the 5 nearest neighbors belong to the class of  $x$ .
- A sample  $x$  will be classified in the borderline category if 2–3 out of its 5 nearest neighbors belong to the class of  $x$ .
- A sample  $x$  will be classified in the rare category if only one nearest neighbor belongs to the class of  $x$ , and this has no more than one neighbor from its same class.
- A sample  $x$  will be classified in the outlier category if all its nearest neighbors are from the opposite class.

## III. DATABASES AND EXPERIMENTAL PROTOCOL

We conducted a pool of experiments on a collection of publicly available gene-expression microarray data sets, which were taken from the Kent Ridge Biomedical Data Set Repository (<http://datam.i2r.a-star.edu.sg/datasets/krbd>). Table I reports the main characteristics of these databases, including the number of genes (features), the number of samples, and the size of each class (here designated as positive and negative).

TABLE I  
CHARACTERISTICS OF THE GENE-EXPRESSION MICROARRAY DATA SETS

	#Genes	#Samples	#Positive	#Negative
Breast	24481	97	46	51
CNS	7129	60	21	39
Colon	2000	62	22	40
Prostate	12600	136	59	77

For the present study, we varied the percentage of genes from 5% to 100% with a step size of 5% by using the ReliefF algorithm, thus yielding 20 different subsets (each one with a percentage of the top-ranked features) for each database. The experiments have been circumscribed to the ReliefF algorithm because this paper aims to analyze how dimensionality of the feature space might affect the proportion of the different types of samples, not to find the best feature selection/ranking method.

### A. The ReliefF Algorithm

The basic idea of the ReliefF algorithm [27] lies on adjusting the weights of a vector  $W = [w(1), w(2), \dots, w(G)]$  with the objective of giving more relevance to features that better discriminate the samples from neighbors of some different class.



It randomly picks out a sample  $x$  and searches for  $k$  nearest neighbors of the same class (hits,  $h_i$ ) and  $k$  nearest neighbors from each of the different classes (misses,  $m_i$ ). If  $x$  and  $h_i$  have different values on feature  $f$ , then the weight  $w(f)$  is decreased because it is interpreted as a bad property of this feature. In contrast, if  $x$  and  $m_i$  have different values on the feature  $f$ , then  $w(f)$  is increased. This process is repeated  $t$  times, and the values of the weight vector  $W$  are updated as follows:

$$w(f) = w(f) - \frac{\sum_{i=1}^k \text{dist}(f, x, h_i)}{t \cdot k} \quad (1)$$

$$+ \sum_{c \neq \text{class}(x)} \frac{P(c)}{1 - P(\text{class}(x))} \cdot \frac{\sum_{i=1}^k \text{dist}(f, x, m_i)}{t \cdot k}$$

where  $P(c)$  is the prior probability of class  $c$ ,  $P(\text{class}(x))$  denotes the probability for the class of  $x$ , and  $\text{dist}(f, x, m_i)$  represents the absolute distance between samples  $x$  and  $m_i$  in the feature  $f$ .

The algorithm assigns negative values to features that are completely irrelevant and the highest scores for the most informative features. In general, one will then select the  $g$  top-ranked features in order to build the classifier with a presumably much smaller subset of features ( $g \ll G$ ). In addition, unlike other well-known ranking methods such as those based on information theory (e.g., mutual information or information gain), the ReliefF algorithm takes care of the dependencies between genes [28].

#### IV. RESULTS AND DISCUSSION

This section is devoted to explore how the number of genes may have an effect on the amount of samples that belong to each type. As far as we know, there has been no systematic analysis on this problem; in fact, previous studies have focused on identifying the types of samples from the minority class in class imbalanced data sets and analyzing how the resampling techniques may alter the distribution/proportion of safe, borderline, rare and outlier samples [14], [24]–[26], [29], [30]

Bearing our purpose in mind, the experiments were as follows. First, we calculated the percentages of positive and negative samples from each type when varying the percentage of genes. Afterwards, we also run six classifiers of different nature over each subset of features: the 1-nearest neighbor (1-NN) rule with the Euclidean distance, a pruned C4.5 decision tree, a support vector machine (SVM) with a linear kernel using the sequential minimal optimization algorithm and a soft-margin  $C = 1.0$ , a normalized Gaussian radial basis function (RBF) neural network with the  $K$ -means clustering algorithm to provide the basis functions, the naive Bayes classifier (NBayes), and a multi-layer perceptron (MLP) with one hidden layer, a learning rate of 0.3 and 500 training epochs.

Fig. 1 shows the percentages of each positive sample type when varying the dimensionality of the feature space for each

database. As can be seen, the percentage of safe samples in the positive class increases and the percentage of borderline positive samples decreases as dimensionality decreases. Although the percentages of rare and outlier samples are generally low, it was observed a very similar behavior to that of the borderline samples. This result could allow to gain some insight into the reasons why classification in lower dimensions is usually easier than in higher dimensions.

Analogously, Fig. 2 displays the percentages of the negative sample types when varying the dimensionality of the feature space for each database. In general, lines in these plots closely match the trend patterns recognized in the plots of Fig. 1, that is, the percentage of safe samples increases and the percentages of the different types of unsafe samples decrease as dimensionality decreases. Notwithstanding, for the safe and borderline samples, we observed an essential difference of behavior between the positive class and the negative class: while the percentages of safe positive samples were usually lower than those of the borderline positive samples, the percentages of safe negative samples always resulted much higher than those of the borderline negative samples. This behavior agrees with the expected one because the negative class corresponds to the majority class and therefore, the probability for a negative sample to be identified as safe is higher than the probability of being classified in some group of the unsafe samples.

Regarding the rare and outlier samples that belong to the negative class, we found that there was no substantial relationship between dimensionality of the feature space and the number of samples in both these types. Nevertheless, this fact should not become especially critical for a given classification problem because the amount of samples that belong to the rare and outlier types is minimal as compared to the total number of safe and borderline samples.

Plots in Fig. 3 correspond to the accuracy achieved by each classification model when applied to each of the 20 subsets. It is possible to observe that the accuracy of all classifiers tends to decrease as the amount of genes increases. A visual comparison between this figure and those of the sample types allows to demonstrate that there exists some significant link (positive correlation) between the dimensionality of the feature space and the distribution of sample types since the highest accuracies were achieved for the subsets with the largest number of safe samples and the smallest number of unsafe samples.

#### V. CONCLUDING REMARKS

As one of the earliest works on investigating the potential connections between feature dimensionality and sample types, this paper has to be viewed as a preliminary study of the effects of dimensionality reduction on the distribution of the different types of samples in a data set.

From the experiments carried out, we have observed that the proportions of safe, borderline, rare and outlier samples vary as the dimensionality of the feature space changes. More specifically, reduction in dimensionality generally leads to a

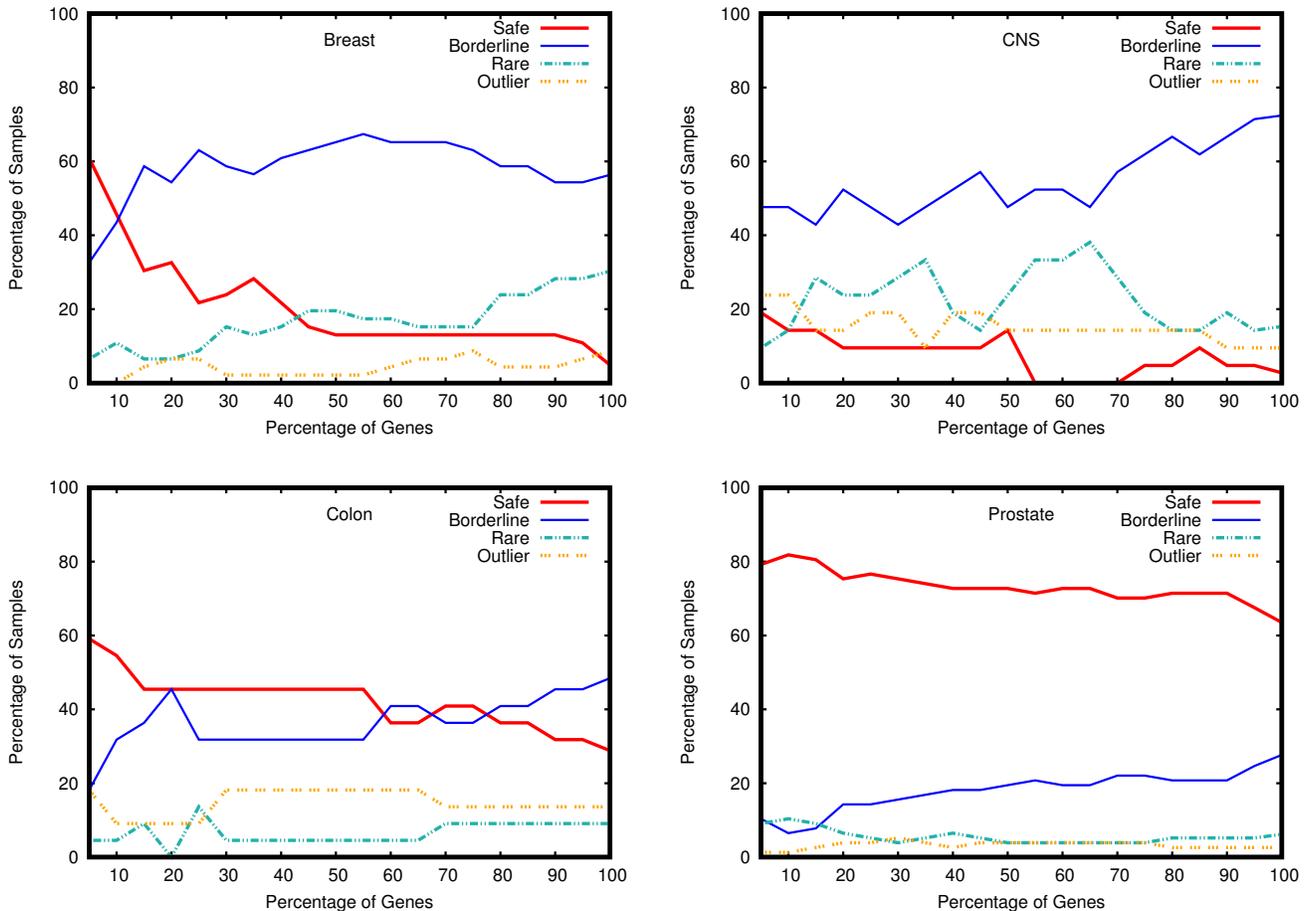


Fig. 1. Plots of the percentage of each type of positive samples when varying the percentage of genes

significant decrease in the amount of borderline samples and an increase in the number of safe samples. As showed in the experiments, this has a direct impact on the performance of classifiers because the classification of safe samples results much easier than the classification of any type of unsafe samples.

Through the characterization of databases by the distribution of their sample types, our hypothesis for further research is that it would be possible to define a meta-learning framework to choose the feature subset with the highest classification performance. Another direction for extending the present paper consists in the combined use of sample types and data complexity measures for the implementation of accurate preprocessing methods.

#### ACKNOWLEDGMENT

This research work has partially been supported by the Mexican PRODEP under Grant No. DSA/103.5/15/7004, the Generalitat Valenciana under Grant No. PROMETEOII/2014/062, and the Universitat Jaume I under Grant No. P1-1B2015-74.

#### REFERENCES

- [1] L. Chen, "Curse of dimensionality," in *Encyclopedia of Database Systems*, L. Liu and M. T. Özsu, Eds. Boston, MA: Springer, 2009, pp. 545–546.
- [2] R. Clarke, H. W. Ransom, A. Wang, J. Xuan, M. C. Liu, E. A. Gehan, and Y. Wang, "The properties of high-dimensional data spaces: implications for exploring gene and protein expression data," *Nat. Rev. Cancer*, vol. 8, no. 1, pp. 37–49, 2008.
- [3] V. Bolón-Canedo, N. Sánchez-Marroño, and A. Alonso-Betanzos, "Recent advances and emerging challenges of feature selection in the context of big data," *Knowl.-Based Syst.*, vol. 86, pp. 33–45, 2015.
- [4] E. R. Dougherty, "Small sample issues for microarray-based classification," *Compar. Func. Genom.*, vol. 2, no. 1, pp. 28–34, 2001.
- [5] L. Wang, F. Chu, and W. Xie, "Accurate cancer classification using expressions of very few genes," *IEEE-ACM T. Comput. Biol. Bioinform.*, vol. 4, no. 1, pp. 40–53, 2007.
- [6] R. Somorjai, B. Dolenko, and R. Baumgartner, "Class prediction and discovery using gene microarray and proteomics mass spectroscopy data: curses, caveats, cautions," *Bioinformatics*, vol. 19, no. 12, pp. 1484–1491, 2003.
- [7] I. Inza, P. Larrañaga, R. Blanco, and A. J. Cerrolaza, "Filter versus wrapper gene selection approaches in DNA microarray domains," *Artif. Intell. Med.*, vol. 31, no. 2, pp. 91–103, 2004.
- [8] Y. Saeys, I. Inza, and P. Larrañaga, "A review of feature selection techniques in bioinformatics," *Bioinformatics*, vol. 23, no. 19, pp. 2507–2517, 2007.
- [9] C. Lazar, J. Taminou, S. Meganck, D. Steenhoff, A. Coletta, C. Molter, V. de Schaetzen, R. Duque, H. Bersini, and A. Nowe, "A survey on filter techniques for feature selection in gene expression microarray analysis,"

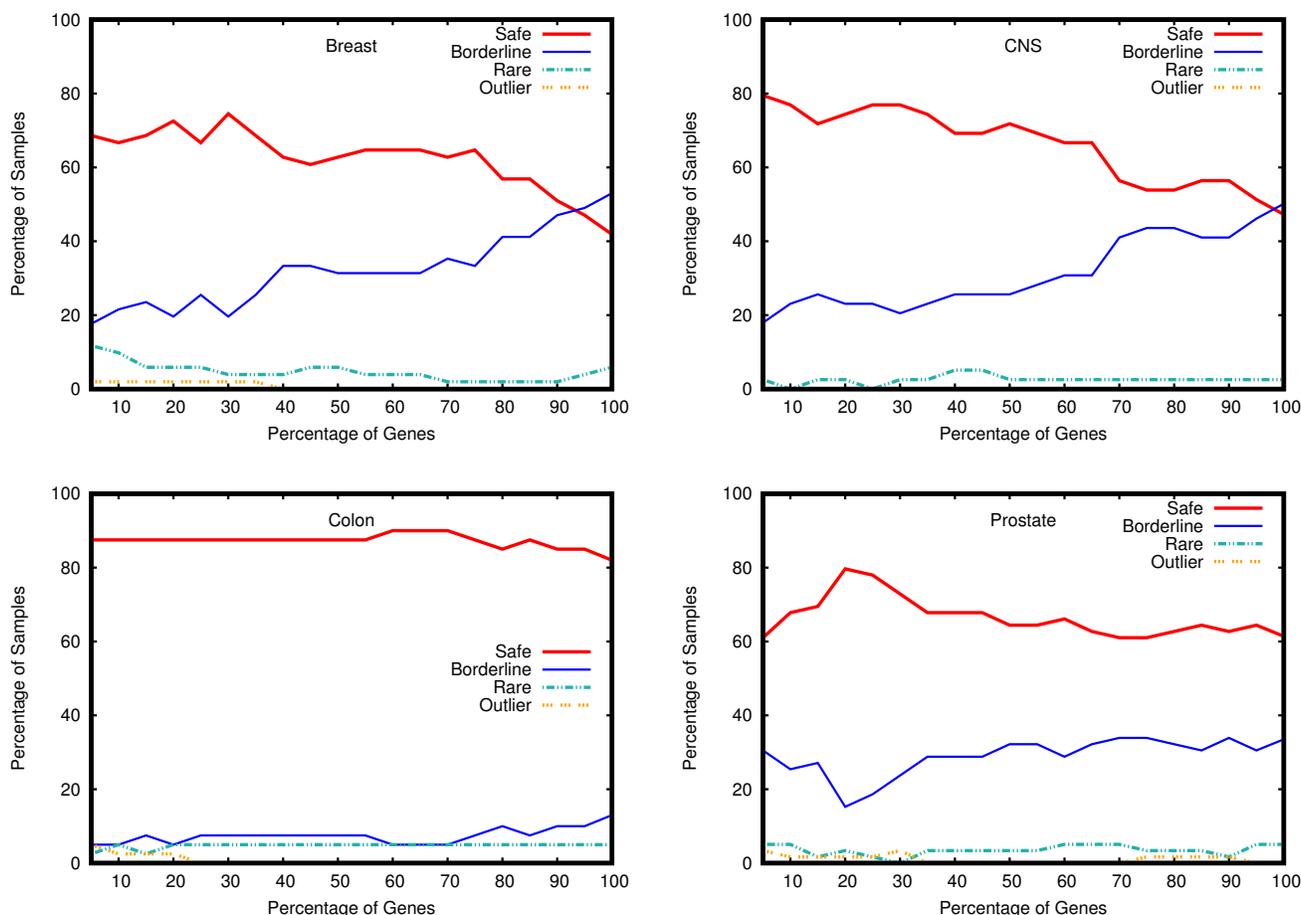


Fig. 2. Plots of the percentage of each type of negative samples when varying the percentage of genes

- IEEE-ACM T. Comput. Biol. Bioinform.*, vol. 9, no. 4, pp. 1106–1119, 2012.
- [10] Z. M. Hira and D. F. Gillies, “A review of feature selection and feature extraction methods applied on microarray data,” *Adv. Bioinformatics*, vol. 2015, no. ID 198363, pp. 1–13, 2015.
- [11] J. C. Ang, A. Mirzal, H. Haron, and H. N. A. Hamed, “Supervised, unsupervised, and semi-supervised feature selection: A review on gene selection,” *IEEE-ACM T. Comput. Biol. Bioinform.*, vol. 13, no. 5, pp. 971–989, 2016.
- [12] I. Guyon and A. Elisseeff, “An introduction to variable and feature selection,” *J. Mach. Learn. Res.*, vol. 3, pp. 1157–1182, 2003.
- [13] M. Kubat and S. Matwin, “Addressing the curse of imbalanced training sets: One-sided selection,” in *Proc. 14th International Conference on Machine Learning*, Nashville, TN, 1997, pp. 179–186.
- [14] K. Napierala and J. Stefanowski, “Types of minority class examples and their influence on learning classifiers from imbalanced data,” *J. Intell. Inf. Syst.*, vol. 46, no. 3, pp. 563–597, 2016.
- [15] R. Baumgartner and R. Somorjai, “Data complexity assessment in undersampled classification of high-dimensional biomedical data,” *Pattern Recogn. Lett.*, vol. 27, no. 12, pp. 1383–1389, 2006.
- [16] O. Okun and H. Priisalu, “Dataset complexity in gene expression based cancer classification using ensembles of k-nearest neighbors,” *Artif. Intell. Med.*, vol. 45, no. 2, pp. 151–162, 2009.
- [17] M. C. P. de Souto, A. C. Lorena, N. Spolaor, and I. G. Costa, “Complexity measures of supervised classifications tasks: A case study for cancer gene expression data,” in *Proc. International Joint Conference on Neural Networks*, Barcelona, Spain, 2010, pp. 1–7.
- [18] V. Bolón-Canedo, N. Sánchez-Marño, A. Alonso-Betanzos, J. Benítez, and F. Herrera, “A review of microarray datasets and applied feature selection methods,” *Inform. Sciences*, vol. 282, pp. 111–135, 2014.
- [19] J. S. Sánchez and V. García, “Addressing the links between dimensionality and data characteristics in gene-expression microarrays,” in *Proc. International Conference on Learning and Optimization Algorithms: Theory and Applications*, Rabat, Morocco, 2018, pp. 1–6.
- [20] A. C. Lorena, I. G. Costa, N. Spolaor, and M. C. de Souto, “Analysis of complexity indices for classification problems: Cancer gene expression data,” *Neurocomputing*, vol. 75, no. 1, pp. 33–42, 2012.
- [21] B. Seijo-Pardo, V. Bolón-Canedo, and A. Alonso-Betanzos, “Using data complexity measures for thresholding in feature selection rankers,” in *Advances in Artificial Intelligence*. Lecture Notes in Computer Science, Springer, 2016, vol. 9868, pp. 121–131.
- [22] L. Morán-Fernández, V. Bolón-Canedo, and A. Alonso-Betanzos, “Can classification performance be predicted by complexity measures? A study using microarray data,” *Knowl. Inf. Syst.*, vol. 51, no. 3, pp. 1067–1090, 2017.
- [23] M. Sun, K. Liu, and Q. Hong, “An ECOC approach for microarray data classification based on minimizing feature related complexities,” in *Proc. 10th International Symposium on Computational Intelligence and Design*, Hangzhou, China, 2017, pp. 300–303.
- [24] J. A. Sáez, B. Krawczyk, and M. Woźniak, “Analyzing the oversampling of different classes and types of examples in multi-class imbalanced datasets,” *Pattern Recogn.*, vol. 57, pp. 164–178, 2016.
- [25] B. Krawczyk, M. Woniak, and F. Herrera, “Weighted one-class classification for different types of minority class examples in imbalanced data,” in *Proc. IEEE Symposium on Computational Intelligence and Data Mining*, Piscataway, NJ, 2014, pp. 337–344.
- [26] P. Skryjowski and B. Krawczyk, “Influence of minority class instance types on SMOTE imbalanced data oversampling,” in *Proc. 1st Interna-*

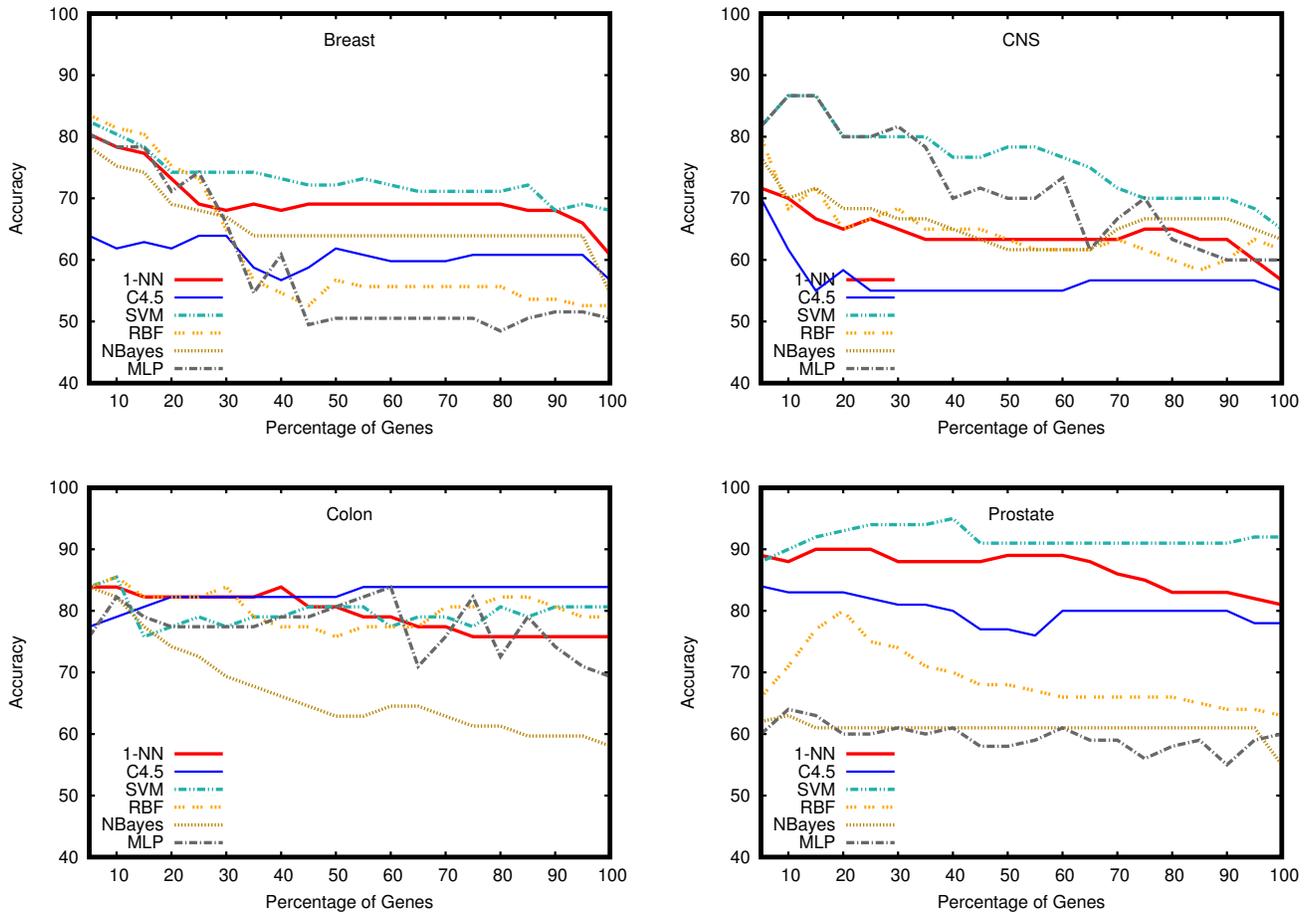


Fig. 3. Classification accuracies when varying the percentage of genes

- tional Workshop on Learning with Imbalanced Domains: Theory and Applications, Skopje, Macedonia, 2017, vol. 74, pp. 7–21.
- [27] M. Robnik-Šikonja and I. Kononenko, “Theoretical and empirical analysis of ReliefF and RReliefF,” *Mach. Learn.*, vol. 53, no. 1–2, pp. 23–69, 2003.
- [28] Y. Peng, W. Li, and Y. Liu, “A hybrid approach for biomarker discovery from microarray gene expression data for cancer classification,” *Cancer Inform.*, vol. 2, pp. 301–311, 2006.
- [29] S. Wang, L. L. Minku, and X. Yao, “Resampling-based ensemble methods for online class imbalance learning,” *IEEE T. Knowl. Data En.*, vol. 27, no. 5, pp. 1356–1368, 2015.
- [30] M. Lango and J. Stefanowski, “The usefulness of roughly balanced bagging for complex and high-dimensional imbalanced data,” in *Proc. 4th International Workshop on New Frontiers in Mining Complex Patterns*. Porto, Portugal: Springer International Publishing, 2016, pp. 93–107.



# Selección de características distribuida en entornos heterogéneos

Verónica Bolón-Canedo  
Grupo LIDIA. DCITIC.  
Universidade da Coruña  
A Coruña, España  
veronica.bolon@udc.es

Rubén Seoane-Martínez  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España

José Luis Morillo-Salas  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
jose.luis.morillo@udc.es

Amparo Alonso-Betanzos  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
ciamparo@udc.es

**Resumen**—Los avances en las Tecnologías de la Información y las Comunicaciones han contribuido a la proliferación de grandes bases de datos. En algunos casos estos datos ya están distribuidos en su origen, pero en otros casos su gran escala hace que el procesamiento en un único nodo sea imposible, y en consecuencia la distribución en varios nodos de cómputo es una opción natural para su manejo. En este trabajo, proponemos una metodología que nos permite distribuir el proceso de selección de características, la mayoría de las veces un paso de preprocesado imprescindible en los conjuntos de alta dimensión actuales, ya que nos permite reducir la dimensión de entrada, seleccionando las características relevantes y eliminando las redundantes y/o irrelevantes. En particular, nuestra propuesta en este artículo se centra en el problema de los conjuntos de datos desbalanceados, bien porque la situación se da ya en origen o bien cuando este contexto en que las distintas clases de datos no están igualmente representadas en las distintas particiones se produce debido a que se debe distribuir el conjunto único original para poder tratarlo. Los resultados experimentales obtenidos demuestran que nuestra aproximación distribuida obtiene resultados de error comparables a la aproximación centralizada, aportando como ventajas una reducción apreciable del tiempo computacional y la capacidad de trabajar eficientemente en entornos de desbalanceo de clases.

**Index Terms**—selección de características, algoritmos distribuidos, conjuntos de datos desbalanceados.

## I. INTRODUCCIÓN

La selección de características (SC) es una técnica de aprendizaje automático en la que se seleccionan los atributos que permiten que un problema esté claramente definido, mientras que los irrelevantes o redundantes se ignoran [1]. Tradicionalmente, un algoritmo de SC se aplica de manera centralizada, es decir, se utiliza un único modelo selector de características sobre todos los datos del conjunto para resolver un problema determinado. Sin embargo, en algunos casos, los datos pueden o bien estar ya distribuidos en varias localizaciones, o bien se puede usar una estrategia de aprendizaje distribuido para repartir en varios nodos de cómputo un conjunto de datos que es demasiado grande para poder ser procesado en un único nodo. De esta forma podemos aprovechar el procesamiento de estos múltiples subconjuntos de datos bien en secuencia o

en paralelo. Existen varias formas de distribuir una tarea de selección de características, aunque las más comunes son:

- los datos están juntos en un conjunto de datos muy grande, por lo que se distribuyen en varios procesadores, se ejecuta un algoritmo de SC idéntico en cada uno y luego los resultados parciales se combinan para obtener un resultado final, y
- los datos pueden estar en diferentes conjuntos de datos situados en diferentes ubicaciones, por lo que se ejecuta un algoritmo de selección de características idéntico en cada uno y los resultados se combinan para obtener un resultado final.

Al respecto, existen varios trabajos en la literatura que realizan la selección de características de forma distribuida [2], [3]. Sin embargo, cuando los datos se distribuyen en varios procesadores, pueden aparecer algunos problemas adicionales, como un alto desequilibrio entre clases en algunos de los nodos, o incluso la situación extrema en la que algunas clases no están representadas en absoluto en algunos de los subconjuntos de datos. El *problema de desequilibrio de clase o desbalanceo* se produce cuando un conjunto de datos está dominado por una clase mayoritaria que tiene significativamente muchas más instancias que las otras clases, llamadas minoritarias. En este caso, los algoritmos de aprendizaje computacional suelen presentar un sesgo hacia las clases mayoritarias, ya que las reglas que predicen correctamente esas instancias se ponderan positivamente a favor de la métrica de precisión, mientras que las reglas específicas que predicen ejemplos de la clase minoritaria generalmente se ignoran. Por lo tanto, las muestras de las clases minoritarias se clasifican erróneamente más a menudo que las de las otras clases [4].<sup>o</sup>

En este trabajo presentamos una metodología para distribuir el proceso de SC, que tiene en cuenta este problema de la posible heterogeneidad de los subconjuntos. Para ello usamos dos alternativas: (i) forzar las particiones del conjunto de datos para mantener el equilibrio entre las clases, y (ii) aplicar técnicas de sobremuestreo (oversampling) cuando el desequilibrio es inevitable.

## II. METODOLOGÍA DISTRIBUIDA

En este trabajo, se detalla la aplicación de una metodología para distribuir el proceso de SC sobre la base de trabajos pre-

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad (proyectos de investigación TIN 2015-65069-C2-1-R y la Red Española de Big Data y Análisis de datos escalable, TIN2016-82013-REDT), y por Fondos de Desarrollo Regional de la Unión Europea.

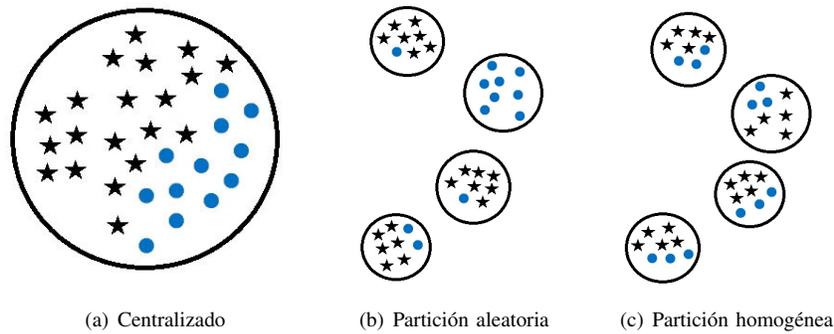


Figura 1. Escenarios centralizado (a) y particiones aleatoria (b) y homogénea (c) en un proceso de selección de características distribuido

vios [5], [6]. Esta metodología consta de tres pasos principales, que son los siguientes:

1. partición de los datos, si éstos no estuviesen ya distribuidos en origen,
2. aplicación del método de SC a cada una de las diferentes particiones realizadas
3. combinación de los resultados.

Debemos de tener en cuenta que los dos primeros pasos se repiten varias rondas ( $r$ ), para garantizar la captura de suficiente información para el paso de combinación de los resultados parciales.

El primer paso de la metodología anterior es el núcleo de este trabajo y consiste en dividir sin reemplazo los datos del conjunto original, asignando grupos de  $n$  muestras a cada subconjunto de datos. Se seguirán dos enfoques principales: *partición aleatoria*, en la que se realizará una distribución aleatoria de los datos en los distintos nodos, y *partición homogénea*, en la que se mantienen las proporciones del conjunto original en cada uno de los subconjuntos obtenidos. Un ejemplo de estos dos tipos de partición, junto con el escenario centralizado en el que todos los datos están juntos, se puede ver en la figura 1.

Después de realizar una partición, el conjunto de datos podría estar desequilibrado (ya sea porque la partición se realizó al azar o porque el conjunto de datos ya estaba desbalanceado en origen). En este caso, nuestra propuesta consiste en aplicar el método de sobremuestreo SMOTE [7], que agrega ejemplos sintéticos de la clase minoritaria al conjunto de datos original hasta que la distribución de clases se equilibre. Para poder conseguir esto, SMOTE genera ejemplos sintéticos de la clase minoritaria utilizando los ejemplos originales de la misma de la siguiente manera: en primer lugar, busca los  $k$  vecinos más cercanos de la muestra de la clase minoritaria que se utilizará como base para la nueva muestra sintética. Luego, en el segmento que une la muestra de la clase minoritaria con uno o todos sus vecinos, se toma aleatoriamente una muestra sintética y se agrega al nuevo conjunto de datos sobremuestreados.

El siguiente paso en la metodología general consiste en aplicar un método de SC en cada partición. Las características que se seleccionan para ser eliminadas reciben un voto y luego, se realiza una nueva ronda que conduce a una nueva

partición del conjunto de datos y se lleva a cabo una nueva iteración de la votación hasta alcanzar el número predefinido de rondas  $r$ . Finalmente, las características que han recibido una cantidad de votos por encima de un umbral predefinido se eliminan. Por lo tanto, se obtiene finalmente un conjunto único de características que se pueden utilizar para entrenar un clasificador  $C$  y probar su rendimiento en un nuevo conjunto de muestras (conjunto de datos de test). Más detalles sobre cómo elegir el umbral de votos se pueden encontrar en [5], [6]. El pseudocódigo de la metodología propuesta se muestra en el algoritmo 1.

```

1  inicializar el vector de votos a 0
2  para cada ronda hacer
3      dividir el conjunto de datos  $\mathbf{d}$  aleatoriamente o
        mantener las proporciones de las clases en
        subconjuntos de datos disjuntos
4      para cada subconjunto de datos hacer
5          si los datos están desbalanceados entonces
6              aplicar SMOTE
7          fin
8          aplicar un algoritmo de selección de características
9          incrementar un voto para cada característica a ser
            eliminada
10     fin
11     eliminar las características cuyo número de votos sea
        superior a un umbral
12     clasificar con el subconjunto de características obtenido
    
```

**Algoritmo 1:** Pseudo-código de la metodología propuesta

### III. RESULTADOS EXPERIMENTALES

En esta sección presentaremos el esquema de experimentación y los resultados obtenidos. Recordemos que los objetivos de la experimentación son dos, (i) poder establecer qué tipo de partición es la más adecuada y (ii) cuál es la influencia del algoritmo de sobremuestreo SMOTE cuando las particiones presentan datos desbalanceados.

#### III-A. Comparación entre las aproximaciones distribuidas y la centralizada

Con este objetivo, hemos seleccionado 6 conjuntos de datos, cuyas características se resumen en la Tabla I, y que están



Cuadro I

CARACTERÍSTICAS DE LOS CONJUNTOS UTILIZADOS EN LA PRIMERA PARTE DE LA EXPERIMENTACIÓN, EN DONDE SOLAMENTE SE UTILIZA SMOTE EN LA CLASE MINORITARIA.

Conjunto	Nº Muestras	Nº Características	Nº Clases	% clase mayoritaria
Connect4	67557	42	3	65.83
Isolet	7797	617	26	3.85
Madelon	2400	500	2	50
Mnist	60000	717	2	50
Ozone	2536	72	2	97.12
Spambase	4601	57	2	60.6

disponibles para su descarga en el UCI Machine Learning Repository <sup>1</sup>.

Aunque la metodología propuesta es genérica, y por lo tanto se puede usar con cualquier método de SC, en este trabajo hemos elegido una suite de cuatro filtros, basados en diferentes tipos de métricas. Concretamente hemos utilizado Correlation-Based Feature Selection (CFS), Consistency-based, Information Gain y ReliefF, todos ellos disponibles en la herramienta de software libre Weka <sup>2</sup>. Para posteriormente poder evaluar los resultados de la selección de características realizada, hemos elegido cuatro clasificadores populares en el estado del arte: C4.5, Naive Bayes, IB1 y Vectores de Máquinas Soporte (en inglés, Support Vector Machine –SVM–). Los experimentos se realizaron en una CPU Core™i3-6100 Intel @3.70 GHz con 16 GB de memoria RAM.

En el primer estudio experimental se compararon tres escenarios diferentes: (i) la aproximación centralizada estándar, (ii) la distribución aleatoria, y (iii) el particionado homogéneo. Para las dos aproximaciones distribuidas (la aleatoria y la homogénea), el número de rondas utilizado fue de 5. Para asegurar una buena fiabilidad en los resultados obtenidos, se realizó una validación *hold-out* estándar, es decir, se dividieron los distintos conjuntos de la tabla I en dos subconjuntos diferentes, con la proporción 2/3 para entrenamiento y 1/3 para prueba, y se repitió esta operación 5 veces. También se han usado test de significación estadística, en primer lugar un test de Friedman para comprobar si existían diferencias significativas para un nivel de significación  $\alpha = 0,5$ , y posteriormente de Nemenyi para obtener aquellos modelos que no son significativamente diferentes a los que obtienen la mayor precisión. Las tablas detalladas con los resultados obtenidos para todas las combinaciones entre conjuntos de datos, métodos de SC y clasificadores pueden verse en el material suplementario que se encuentra en <sup>3</sup>.

La Tabla II muestra un resumen de este primer conjunto de experimentos, en los que la meta es comparar los tres escenarios (centralizado, partición aleatoria y partición homogénea), independientemente de la aplicación de la técnica de *oversampling* SMOTE. La tabla muestra los resultados para cada combinación de conjunto de datos y escenario, teniendo en cuenta dos medidas de evaluación diferentes: la precisión de la clasificación y el valor del índice kappa. El

motivo de incluir el valor de Kappa es porque éste evalúa la calidad del aprendizaje teniendo en cuenta las situaciones en las que el conjunto de datos está desequilibrado y el clasificador aprende correctamente la clase mayoritaria, pero sistemáticamente clasifica erróneamente las instancias de la clase minoritaria. En las primeras dos filas de cada conjunto de datos, se puede consultar el promedio de la precisión de clasificación y Kappa; y en las últimas dos filas se muestran los valores máximos de precisión y Kappa (y la combinación que lo obtiene entre paréntesis). Como se puede ver, los enfoques distribuidos (partición aleatoria y homogénea) son una buena solución para disminuir el tiempo computacional sin implicar una degradación en el rendimiento de clasificación. Comparando los dos enfoques distribuidos, vale la pena señalar que, en general, el enfoque homogéneo parece obtener resultados más estables, mientras que con la partición aleatoria puede ocurrir que en un caso particular la proporción de las clases sea óptima y por esa razón obtiene los mejores resultados en algunos casos.

Como era de esperar, los enfoques distribuidos reducen significativamente el tiempo de ejecución en comparación con el enfoque centralizado (ver detalles en el material complementario <sup>3</sup>), aunque depende concretamente tanto del método de selección empleado como del conjunto de datos. Cuando el conjunto de datos es pequeño, la mejora es leve (por ejemplo, de 0.40s a 0.34s en el conjunto Ozone) pero en conjuntos de datos más grandes, la mejora es considerable (por ejemplo, de 820.46s a 0.83s en el conjunto Connect-4). Es remarcable también el buen rendimiento obtenido por los métodos de selección ReliefF y Consistency-based.

### III-B. Utilización de SMOTE en las particiones

El segundo grupo de experimentos consiste en la evaluación de la efectividad de SMOTE ante el problema del desbalanceo de clases. La comparación se realizó entre los dos escenarios distribuidos (partición aleatoria y homogénea). Debemos tener en cuenta que, al aplicar la partición aleatoria, es posible que algunos subconjuntos de datos estén desbalanceados, incluso si el conjunto de datos completo no lo estaba. Por lo tanto, hemos aplicado SMOTE cuando el subconjunto de datos no estaba balanceado (ya sea bien debido a la existencia de esta circunstancia en clase original, o bien debido a la partición aleatoria). Se han realizado diferentes experimentos con diferentes porcentajes de sobremuestreo. Por ejemplo, si la clase minoritaria tiene 40 muestras y aplicamos SMOTE

<sup>1</sup><http://archive.ics.uci.edu/ml/index.php>

<sup>2</sup><http://www.cs.waikato.ac.nz/ml/weka/>

<sup>3</sup><http://lidiagroup.org/index.php/en/materials-en.html>

Conjunto		Centralizado	Aleatorio	Homogéneo
Connect4	Precisión (media)	65.72	67.52	67.52
	Kappa (media)	0.175	0.184	0.188
	Precisión (max)	73.37 (Cons+C4.5)	74.12 (Rel+C4.5)	72.81 (IG+C4.5)
	Kappa (max)	0.454 (Cons+C4.5)	0.425 (Rel+C4.5)	0.399 (Rel+C4.5)
Isolet	Precisión (media)	63.92	69.12	68.64
	Kappa (media)	0.624	0.678	0.673
	Precisión (max)	84.60 (Rel+SVM)	85.51 (Rel+SVM)	83.87 (Rel+SVM)
	Kappa (max)	0.839 (Rel+SVM)	0.849 (Rel+SVM)	0.832 (Rel+SVM)
Madelon	Accuracy (media)	74.64	72.25	75.32
	Kappa (media)	0.492	0.444	0.506
	Accuracy (max)	88.75 (Varios+IB1)	81.75 (Rel+C4.5)	89.62 (Rel+IB1)
	Kappa (max)	0.774 (Varios+IB1)	0.636 (Rel+C4.5)	0.792 (Rel+IB1)
MNIST	Precisión (media)	81.04	83.68	83.83
	Kappa (media)	0.620	0.672	0.675
	Precisión (max)	89.96 (Rel+IB1)	96.33 (Cons+IB1)	95.83 (Rel+IB1)
	Kappa (max)	0.799 (Rel+IB1)	0.926 (Cons+IB1)	0.916 (Rel+IB1)
Ozone	Precisión (media)	92.09	91.06	90.87
	Kappa (media)	0.1014	0.1012	0.092
	Precisión (max)	97.12 (Todos+SVM)	96.99 (Todos+SVM)	96.97 (Todos+SVM)
	Kappa (max)	0.189 (Cons+C4.5)	0.215 (Cons+C4.5)	0.180 (IG+IB1)
Spambase	Precisión (media)	86.66	87.18	87.63
	Kappa (media)	0.723	0.732	0.742
	Precisión (max)	91.42 (CFS+C4.5)	91.24 (CFS+C4.5)	91.73 (CFS+C4.5)
	Kappa (max)	0.819 (CFS+C4.5)	0.816 (CFS+C4.5)	0.826 (CFS+C4.5)

Cuadro II

RESUMEN DE LOS RESULTADOS OBTENIDOS PARA LAS APROXIMACIONES DISTRIBUIDAS Y CENTRALIZADA. NO SE HA UTILIZADO EL MÉTODO SMOTE EN LAS APROXIMACIONES DISTRIBUIDAS.

con un nivel de 100, significa que se generan 40 muestras sintéticas, si el nivel es 200, significa que se generan 80 nuevas muestras. Además, incluimos la opción “auto”, que consiste en aplicar SMOTE de tal forma que las clases queden completamente balanceadas.

Conjunto	Precisión	Kappa	Escenario	Combinación	SMOTE
Isolet	85.68	0.851	Aleatorio	Rel+SVM	Auto
Madelon	89.63	0.792	Homogéneo	Rel+IB1	0
MNIST	96.34	0.926	Aleatorio	Cons+IB1	0
Connect4	74.12	0.425	Aleatorio	Rel+C4.5	0
	72.90	0.442	Aleatorio	Rel+C4.5	100
Ozone	97.28	0	Homogéneo	All+SVM	100
	90.82	0.302	Homogéneo	Rel+SVM	600
Spambase	91.73	0.826	Homogéneo	CFS+C4.5	0
	91.68	0.827	Homogéneo	CFS+C4.5	300

Cuadro III

RESUMEN DE LOS RESULTADOS OBTENIDOS USANDO SMOTE EN LAS CLASES MINORITARIAS.

La tabla III muestra el resumen de los mejores resultados obtenidos al aplicar diferentes niveles de sobremuestreo con SMOTE a los subconjuntos de datos. En la primera fila de cada conjunto de datos, se muestra la opción con la mayor precisión, mientras que la segunda fila representa la opción con el valor Kappa más alto. Cuando el mejor resultado para ambas mediciones de evaluación se logra mediante la misma combinación y escenario, solo se muestra una fila. Como era de esperar, la aplicación de una técnica de sobremuestreo no es necesaria en el caso de conjuntos de datos equilibrados (Isolet, Madelon, MNIST). En el caso de Isolet, la aplicación de SMOTE en el escenario de partición aleatoria ha resultado provechosa, ya que en este caso es posible que los conjuntos de datos equilibrados produzcan subconjuntos de datos no balanceados (especialmente para Isolet, con un alto número

```

1  para repeticiones hacer
2  |   dividir el conjunto de datos d aleatoriamente en
3  |   subconjuntos disjuntos de datos train y test
4  |   calcular la clase mayoritaria del conjunto de train
5  |   para cada nivel Smote minoritaria hacer
6  |       para cada nivel Smote mayoritaria hacer
7  |           train = SMOTE(clase_mayoritaria, train)
8  |           train = SMOTE(clase_minoritaria, train)
9  |           para filtros hacer
10 |               train_filtrado = sel_car(filtro,train)
11 |               para clasificador hacer
11 |                   clasificar(clasificador, train_filtrado,
11 |                       test)
11 |               fin
11 |           fin
11 |       fin
11 |   fin
11 |   fin
    
```

**Algoritmo 2:** Pseudo-código de la metodología propuesta usando SMOTE también en la clase mayoritaria

de clases). Por el contrario, los conjuntos de datos desbalanceados (Connect4, Ozone y Spambase) son buenos candidatos para mejorar sus resultados después de aplicar SMOTE. De hecho, la Tabla III muestra que la aplicación del método de sobremuestreo mejora los valores Kappa, lo que significa que el aprendizaje de las clases es mejor. Hay que recordar que la clase mayoritaria de ozono tiene el 97.12 % de las muestras, por lo que al obtener una precisión de clasificación del 97.28 % es posible que clasifique correctamente todas las muestras de la clase mayoritaria, pero solo unas pocas de la clase minoritaria. Después de aplicar el método de sobremuestreo, la precisión cae al 90.82 %, probablemente porque el clasificador no está tan sobreajustado para aprender la clase mayoritaria



y tiene una tasa de verdaderos positivos más alta en la clase minoritaria.

Finalmente, se realizó un tercer conjunto de experimentos, en los que se utiliza también la técnica SMOTE para añadir también muestras sintéticas en la clase mayoritaria, no sólo en la minoritaria, de forma que todas las clases, mayoritarias y minoritarias, cuenten en sus subconjuntos con muestras sintéticas, como se puede ver en el algoritmo 2.

Para realizar este tercer bloque de experimentos se utilizaron dos tipos de conjuntos, los que denominamos con la etiqueta *normal* en la tabla IV, que son conjuntos de datos en los que el número de muestras es mucho mayor que el número de características, y conjuntos de datos del tipo *Microarrays* [8], obtenidos de investigaciones sobre la clasificación de casos de cáncer, que tienen un elevado número de características y un número muy pequeño de muestras (ver tabla IV). La idea es comprobar no sólo si el realizar SMOTE en todas las clases mejora el resultado, al tener muestras sintéticas en todas ellas, sino también si el balance entre muestras y características influye en los resultados. Se han repetido de nuevo los experimentos, pero en este caso además se han añadido muestras sintéticas también en la clase mayoritaria, utilizando SMOTE con porcentajes de 20, 40 y 100. Al igual que anteriormente, se han obtenido valores para todas las posibles combinaciones de clasificador, filtro y combinación de porcentajes de SMOTE en la clase mayoritaria. En la tabla V se pueden ver los resultados obtenidos para todos los conjuntos de la tabla IV sin SMOTE, con la alternativa de SMOTE en la clase minoritaria y con la alternativa de usar SMOTE en todas las clases.

Como podemos ver en la tabla V, la alternativa SMOTE en las clases minoritaria y mayoritaria conjuntamente es siempre la opción que alcanza la precisión máxima, con los valores de índice kappa más altos (en ocasiones, otras alternativas consiguen idénticas kappas, y la alternativa SMOTE sólo en minoritaria empata en precisión máxima en 5 de los 12 conjuntos). No parecen existir grandes diferencias entre los dos tipos de conjuntos, si bien la diferencia en precisión media entre las dos alternativas usando SMOTE en los conjuntos microarray es menor que en el caso de los conjuntos que hemos denominado normales.

#### IV. CONCLUSIONES Y TRABAJO FUTURO

Hemos presentado una metodología para la selección de características distribuida, tratando de resolver el problema del desbalanceo de los datos en las diferentes particiones. Para ello, hemos forzado a las particiones de datos en los diferentes nodos a mantener la misma distribución de clase que el conjunto de datos original y hemos aplicado la técnica de sobremuestreo (oversampling) SMOTE. Los resultados experimentales en siete conocidos conjuntos de datos han demostrado que:

- El enfoque distribuido — partición aleatoria u homogénea — es competitivo cuando se compara con el enfoque centralizado estándar, incluso en algunos casos mejorando el rendimiento de clasificación.

- La partición homogénea obtiene resultados más estables que la partición aleatoria.
- La aplicación de SMOTE en las clases minoritarias (uso estándar del procedimiento), mejora la calidad del aprendizaje en conjuntos de datos desbalanceados, en algunos casos a expensas de una ligera disminución en la precisión general.
- Además al aplicar el método propuesto con un porcentaje pequeño de SMOTE también en la clase mayoritaria se aprecia una mejora en la precisión máxima obtenida en todos los conjuntos de datos. Además, si bien es cierto que esta última alternativa no obtiene prácticamente en ningún caso los mejores valores de precisiones medias, sí que consigue obtener los valores de kappa más altos, por lo que el método presenta una mayor robustez.

Como trabajo futuro, nos planteamos probar otros métodos para tratar la heterogeneidad, como puede ser el caso de las técnicas de submuestreo (undersampling en inglés), ponderación, etc.

#### REFERENCIAS

- [1] I. Guyon. *Feature extraction: foundations and applications*, volume 207. Springer, 2006.
- [2] L. Morán-Fernández, V. Bolón-Canedo, and A. Alonso-Betanzos. Centralized vs. distributed feature selection methods based on data complexity measures. *Knowledge-Based Systems*, 117:27–45, 2017.
- [3] V. Bolón-Canedo, N. Sánchez-Maróño, and Alonso-Betanzos. Distributed feature selection: An application to microarray data classification. *Applied Soft Computing*, 30:136–150, 2015.
- [4] H. He and E. A. Garcia. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9):1263–1284, 2009.
- [5] V. Bolón-Canedo, N. Sánchez-Maróño, and J. Cerviño-Rabuñal. Scaling up feature selection: a distributed filter approach. In *Conference of the Spanish Association for Artificial Intelligence*, pages 121–130. Springer, 2013.
- [6] V. Bolón-Canedo, N. Sánchez-Marono, and J. Cervino-Rabunal. Toward parallel feature selection from vertically partitioned data. In *Proceedings of ESANN 2014*, pp. 395–400, 2014.
- [7] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer. Smote: synthetic minority over-sampling technique. *arXiv preprint arXiv:1106.1813*, 2011.
- [8] V. Bolón-Canedo, N. Sánchez-Maróño, A. Alonso-Betanzos, J.M. Benítez, and F. Herrera. A review of microarray datasets and applied feature selection methods. *Information Sciences*, 282:111–135, 2014.



Cuadro IV

CARACTERÍSTICAS DE LOS CONJUNTOS DEL TERCER BLOQUE DE EXPERIMENTACIÓN, CON MUESTRAS SINTÉTICAS EN LA CLASE MAYORITARIA

Conjunto	Tipo	Nº Muestras	Nº Características	Nº Clases	% clase mayoritaria
Arrhythmia	Normal	452	279	16	54.2
Connect4	Normal	67557	42	3	65.83
Musk2	Normal	6598	168	2	63
Nomao	Normal	34465	120	2	71.44
Ozone	Normal	2536	72	2	97.12
Spambase	Normal	4601	57	2	60.6
Weight	Normal	4024	90	5	34.04
Brain	Microarray	21	12625	2	67
CNS	Microarray	60	7129	2	75
Colon	Microarray	62	2000	2	65
Gli85	Microarray	85	22283	2	69
Ovarian	Microarray	253	15154	2	64

Conjunto		Sin SMOTE	Solo SMOTE minoritaria	SMOTE minoritaria + mayoritaria
Arrhythmia	Precisión (media)	<b>63.07</b>	62.63	62.07
	Kappa (media)	0.739	0.746	<b>0.774</b>
	Precisión (max)	68.34 (CFS+Naive)	67.68 (CFS+Naive+100)	<b>68.74</b> (Rel+SVM+300+40)
	Kappa (max)	<b>1</b> (Todos+IB1)	<b>1</b> (Todos+IB1+Todos)	<b>1</b> (Todos+IB1+Todos+Todos)
Connect4	Precisión (media)	66.14	<b>66.20</b>	62.15
	Kappa (media)	0.163	0.430	<b>0.478</b>
	Precisión (max)	76.12 (Cons+C4.5)	77.88 (Cons+C4.5+600)	<b>78.21</b> (Cons+C4.5+100+20)
	Kappa (max)	0.777 (Cons+C4.5)	<b>1</b> (Cons+IB1+Todos)	<b>1</b> (Cons+IB1+Todos+Todos)
Musk2	Precisión (media)	<b>89.41</b>	87.35	85.17
	Kappa (media)	0.672	0.687	<b>0.739</b>
	Precisión (max)	95.62 (Cons+C4.5)	95.44 (CFS+C4.5+100)	<b>95.72</b> (Cons+C4.5+100+40)
	Kappa (max)	<b>1</b> (Todos+IB1)	<b>1</b> (Varios+IB1+Varios)	<b>1</b> (Varios+IB1+Todos+Todos)
Nomao	Precisión (media)	<b>85.75</b>	84.22	83.94
	Kappa (media)	0.646	0.693	<b>0.723</b>
	Precisión (max)	94.34 (Cons+C4.5)	94.52 (Cons+C4.5+300)	<b>94.70</b> (Cons+C4.5+Auto+100)
	Kappa (max)	0.964 (Cons+C4.5)	<b>1</b> (Cons+IB1+Todos)	<b>1</b> (Cons+IB1+Todos+Todos)
Ozone	Precisión (media)	<b>92.36</b>	91.88	88.58
	Kappa (media)	0.271	0.506	<b>0.628</b>
	Precisión (max)	96.99 (Cons+Todos)	<b>97.02</b> (Rel+SVM+600)	<b>97.02</b> (Rel+SVM+300+Varios)
	Kappa (max)	0.982 (Info+Rel)	<b>1</b> (CFS+IB1+Todos)	<b>1</b> (CFS+IB1+Todos+Todos)
Spambase	Precisión (media)	85.92	<b>87.45</b>	87.11
	Kappa (media)	0.800	0.858	<b>0.859</b>
	Precisión (max)	92.27 (CFS+C4.5)	92.79 (CFS+C4.5+300)	<b>92.85</b> (CFS+C4.5+Auto+100)
	Kappa (max)	0.998 (Cons+IB1)	<b>1</b> (Cons+IB1+Auto)	<b>1</b> (Cons+IB1+Varios+Varios)
Weight	Precisión (media)	84.40	85.44	<b>86.33</b>
	Kappa (media)	0.803	0.829	<b>0.851</b>
	Precisión (max)	<b>100</b> (Cons+Varios)	<b>100</b> (Cons+Varios+Todos)	<b>100</b> (Varios+C4.5+Todos+Todos)
	Kappa (max)	<b>1</b> (Cons+Varios)	<b>1</b> (Varios+IB1+Varios)	<b>1</b> (Varios+IB1+Varios+Varios)
Brain	Precisión (media)	59.11	<b>62.27</b>	62.14
	Kappa (media)	0.882	0.889	<b>0.904</b>
	Precisión (max)	82.86 (Info+C4.5)	<b>94.29</b> (CFS+C4.5+Todos)	<b>94.29</b> (CFS+C4.5+Todos+Todos)
	Kappa (max)	<b>1</b> (CFS+Todos, Info+Todos)	<b>1</b> (CFS+Todos, Info+Todos)	<b>1</b> (CFS+Todos, Info+Todos)
CNS	Precisión (media)	55.38	<b>58.98</b>	58.13
	Kappa (media)	0.867	0.910	<b>0.921</b>
	Precisión (max)	65 (Cons+SVM)	<b>70</b> (CFS+C4.5+600)	<b>70</b> (CFS+Naive+300+20)
	Kappa (max)	<b>1</b> (Todos+IB1)	<b>1</b> (Todos+IB1+Todos)	<b>1</b> (Todos+IB1+Todos+Todos)
Colon	Precisión (media)	<b>77.62</b>	77.17	76.81
	Kappa (media)	0.861	0.913	<b>0.920</b>
	Precisión (max)	86.67 (Naive+Rel)	87.62 (Info+Naive+Auto)	<b>88.67</b> (Rel+Naive+Auto+20)
	Kappa (max)	<b>1</b> (Todos+IB1)	<b>1</b> (Todos+IB1+Todos)	<b>1</b> (Todos+IB1+Todos+Todos)
Gli85	Precisión (media)	77.99	<b>80.40</b>	80.08
	Kappa (media)	0.944	0.969	<b>0.976</b>
	Precisión (max)	85.71 (Info+SVM)	88.57 (Cons+IB1+Varios)	<b>90</b> (CFS+IB1+Auto+100)
	Kappa (max)	<b>1</b> (Todos+IB1)	<b>1</b> (Todos+IB1+Todos)	<b>1</b> (Todos+IB1+Todos+Todos)
Ovarian	Precisión (media)	97.68	98.04	<b>98.09</b>
	Kappa (media)	0.989	0.994	<b>0.995</b>
	Precisión (max)	<b>100</b> (CFS+SVM)	<b>100</b> (CFS+SVM+Todos)	<b>100</b> (CFS+Varios+Varios)
	Kappa (max)	<b>1</b> (CFS+SVM, Todos+IB1)	<b>1</b> (CFS+SVM+Todos, Todos+IB1+Todos)	<b>1</b> (Todos+IB1+Todos+Todos)

Cuadro V

RESUMEN DE LOS RESULTADOS OBTENIDOS UTILIZANDO LAS TRES APROXIMACIONES, SIN UTILIZAR SMOTE, USANDO SMOTE SÓLO EN LA CLASE MINORITARIA—UTILIZACIÓN ESTÁNDAR— Y USANDO SMOTE EN TODAS LAS CLASES.



# Local sets for multi-label instance selection\*

Álvar Arnaiz-González  
Dpto. Ingeniería Civil  
Universidad de Burgos  
Burgos, Spain  
alvarag@ubu.es

José-Francisco Díez-Pastor  
Dpto. Ingeniería Civil  
Universidad de Burgos  
Burgos, Spain  
jfdpastor@ubu.es

Juan J Rodríguez  
Dpto. Ingeniería Civil  
Universidad de Burgos  
Burgos, Spain  
jjrodriguez@ubu.es

César García-Osorio  
Dpto. Ingeniería Civil  
Universidad de Burgos  
Burgos, Spain  
cgosorio@ubu.es

**Abstract**—This is a summary of our article published in *Applied Soft Computing* [1], presented to the Multi-Conference CAEPIA'18 KeyWorks.

**Index Terms**—multi-label classification, data reduction, instance selection, nearest neighbor, local set

## I. SUMMARY

Single-label classification is a predictive data mining task that consists of assigning a label to an instance for which the label is unknown. Multi-label classification presents a similar task, although the difference is that the instances have a collection of labels, known as a labelset, rather than only one label. The maximum size of the labelset is determined by the number of different labels in the data set. The aforementioned labelset concept can also be considered as a sequence of binary output attributes (as many attributes as there are labels in the whole data set). Each attribute indicates whether the corresponding label is applicable to the instance. Only one of the attributes is active in single-label problems, while several attributes may be active in multi-label problems [5]. In other words, the labels in multi-label learning are not mutually exclusive [8]. This feature implies a much harder and more challenging problem, due to the high relevance of the relations between the different labels [10].

Despite the well-established usefulness of single-label instance selection, there are still very few methods for multi-label classification. To the best of our knowledge, only two instance selection methods for multi-label have been developed. Since both algorithms are based on Wilson Editing (ENN) [9], to avoid any confusion with the acronyms, we refer to them by the initials of their authors: the KADT method [6] and the CRJH method [3]. In this paper, we have attempted to fill that gap by proposing a new technique for computing local sets in multi-label data sets. This new proposal was used to adapt two single-label instance selection methods, LSSm and LSBo, for multi-label problems. The adaptation was tested against the few instance selection methods existing for multi-label learning and against the classifiers ( $MLkNN$  [11] and IBLR-ML [4]) trained on the whole data sets.

The main contributions of the paper were:

- The definition of the local set concept in the context of multi-label data sets.
- The proposal that defines two new instance selection methods, based on the adaptation of single-label classification algorithms to multi-label learning: LSBo and LSSm [7].
- The experimental evaluation of the new algorithms. The new methods were compared with the few existing algorithms.

Instance selection methods usually focus on boundaries between classes. Boundaries are the keystone of the predictive process, because they define whether an instance belongs to one class or another. The simplest classification problem is a binary class data set: there is only one class, thus one instance may or may not belong to it (in practice, this task is similar to determining one of two categories to which the instance belongs). In multi-class classification, more classes are present but, as in the previous case, each instance can only belong to one. The challenge that emerges in multi-label data sets is that instances can belong to more than one class at the same time, which blurs the boundaries (because different labels overlap).

The concept of local set has been used for designing several instance selection algorithms for single-label data sets [2], [7]. Local sets are defined by the nearest enemy, which is straightforward to compute in single-label data sets. The problem with multi-label data sets is how the nearest enemy is defined: it is no trivial task, because every single instance has a set of labels, rather than only one, as in single-label classification. An intuitive solution would be to consider each labelset (the vector of labels of an instance) as a class in itself. However, the results of several experiments have demonstrated that this approach is of little or no use, due to the large amount of different labelsets that multi-label data sets usually have. For example, for a data set with three different classes, the number of different labelsets could be up to  $2^3 = 8$ ; if a data set has nine labels, the number of labelsets could reach  $2^9 = 512$ . The number of possible labelsets therefore increases exponentially with the number of labels. Hence, local sets calculated in this way will be too small (many of them only made up of a single instance) and, therefore, the algorithms based on local sets would not work properly.

The proposal that was presented in the paper was to use the Hamming loss (calculated over labelsets) to measure the

We would like to thank the *Ministerio de Economía y Competitividad* of the Spanish Government for financing the project TIN2015-67534-P (MINECO/FEDER, UE) and the *Junta de Castilla y León* for financing the project BU085P17 (JCyL/FEDER, UE) both cofinanced from European Union FEDER funds.

degree of difference in the labelsets<sup>1</sup>. If the Hamming loss between the labelsets of two instances is greater than a predefined threshold, the instances are considered to be of different ‘classes’. This concept of *class* can be seen as a ‘soft-class’ in the same sense as in regression data sets. The Hamming distance is computed as follows:

$$\text{Hamming distance}(\mathbf{a}, \mathbf{b}) = |\omega_{\mathbf{a}} \Delta \omega_{\mathbf{b}}| \quad (1)$$

where,  $\omega_{\mathbf{a}}$  and  $\omega_{\mathbf{b}}$  are the labelsets of instances  $\mathbf{a}$  and  $\mathbf{b}$ , respectively, and  $\Delta$  is the symmetric difference between two labelsets<sup>2</sup>.

The Hamming distance according to the previous definition is a whole number. The Hamming loss value is commonly used in multi-label learning  $HL \in [0, 1]$ .

$$\text{Hamming loss}(\mathbf{a}, \mathbf{b}) = \frac{1}{|\Omega|} |\omega_{\mathbf{a}} \Delta \omega_{\mathbf{b}}| \quad (2)$$

Pseudocode 1 shows the proposed method for local set calculation in multi-label data sets. It has two inputs: the multi-label data set and the value of the Hamming loss threshold that determines when two labelsets are considered distinct. The function has two outputs: an array of local sets and an array of nearest enemies. Every single instance has its local set (made of one or more instances) and its nearest enemy.

---

**Algorithm 1:** Function `computeLocalSets`: computes the local sets of a multi-label data set.

---

**Input:** A training set  $X = \{(\mathbf{x}_1, \omega_1), \dots, (\mathbf{x}_n, \omega_n)\}$ , a threshold  $\theta$

**Output:** The local sets  $LSS = \{\text{lss}_1, \dots, \text{lss}_n\}$ , the nearest enemy of each instance  $NE = \{ne_1, \dots, ne_n\}$

```

1 for  $i \in \{1..n\}$  do
2    $\text{lss}_i \leftarrow \emptyset$ 
3    $\text{dist\_ne}_i \leftarrow \infty$ 
4   /* Find the nearest enemy of  $\mathbf{x}_i$  */
5   for  $j \in \{1..n\}$  do
6      $d \leftarrow \text{EuclideanDistance}(\mathbf{x}_i, \mathbf{x}_j)$ 
7     if  $\text{HammingLoss}(\omega_i, \omega_j) > \theta$  and  $d < \text{dist\_ne}_i$ 
8       then
9          $ne_i \leftarrow \mathbf{x}_j$ 
10         $\text{dist\_ne}_i \leftarrow d$ 
11      /* Compute the local set of  $\mathbf{x}_i$  */
12      for  $j \in \{1..n\}$  do
13        if  $\text{EuclideanDistance}(\mathbf{x}_i, \mathbf{x}_j) < \text{dist\_ne}_i$  then
14           $\text{lss}_i \leftarrow \text{lss}_i \cup \{\mathbf{x}_j\}$ 

```

---

After the calculation of local sets, any local set-based algorithm can be used without changes. In the experimental

<sup>1</sup>We decided to use Hamming loss, because its computation is fast and it is a commonly used measure in multi-label learning.

<sup>2</sup>The symmetric difference is the exclusive disjunction (XOR) of two sets, that is the set of all elements that are in one set, but not in the other set.

study, we considered LSSm and LSBo, because their use of local sets is more robust than the use of local sets in ICF (the heuristic used in ICF has fundamental problems that were reported in [7]).

The experimental study used a broad range of data sets from different domains, several multi-label measures and statistical tests. The results revealed the two main benefits of our proposal: *i*) HDLSSm, as an edition algorithm, is not only capable of outperforming the other instance selection methods in terms of its results, but it also capable of outperforming the classifier trained with the whole data set; *ii*) HDLSBo, as a condensed algorithm, achieved a remarkable compression, while maintaining a statistically equivalent performance to the performance of the other methods. Furthermore, the existence of a threshold for controlling local set sizes implies an adaptable and versatile proposal.

## REFERENCES

- [1] Álvarez Arnaiz-González, José F. Díez-Pastor, Juan J. Rodríguez, and César García-Osorio. Local sets for multi-label instance selection. *Applied Soft Computing*, 68:651–666, 2018.
- [2] Henry Brighton and Chris Mellish. *On the Consistency of Information Filters for Lazy Learning Algorithms*, pages 283–288. Springer Berlin Heidelberg, Berlin, Heidelberg, 1999.
- [3] Francisco Charte, Antonio J. Rivera, María J. del Jesus, and Francisco Herrera. MLeNN: A first approach to heuristic multilabel undersampling. In *Intelligent Data Engineering and Automated Learning – IDEAL 2014: 15th International Conference, Salamanca, Spain, September 10–12, 2014. Proceedings*, pages 1–9, Cham, 2014. Springer International Publishing.
- [4] Weiwei Cheng and Eyke Hüllermeier. Combining instance-based learning and logistic regression for multilabel classification. *Machine Learning*, 76(2):211–225, Sep 2009.
- [5] Francisco Herrera, Francisco Charte, Antonio J. Rivera, and María J. del Jesus. *Multilabel Classification: Problem Analysis, Metrics and Techniques*. Springer Publishing Company, Incorporated, 2016.
- [6] Sawsan Kanj, Fahed Abdallah, Thierry Dencœux, and Kifah Tout. Editing training data for multi-label classification with the k-nearest neighbor rule. *Pattern Analysis and Applications*, 19(1):145–161, 2016.
- [7] Enrique Leyva, Antonio González, and Raúl Pérez. Three new instance selection methods based on local sets: A comparative study with several approaches from a bi-objective perspective. *Pattern Recognition*, 48(4):1523–1537, 2015.
- [8] Newton Spolaôr, Maria Carolina Monard, Grigorios Tsoumakas, and Huei Diana Lee. A systematic review of multi-label feature selection and a new method based on label construction. *Neurocomputing*, 180:3–15, 2016. Progress in Intelligent Systems Design Selected papers from the 4th Brazilian Conference on Intelligent Systems (BRACIS 2014).
- [9] Dennis L. Wilson. Asymptotic properties of nearest neighbor rules using edited data. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-2(3):408–421, July 1972.
- [10] Zoulficar Younes, Fahed Abdallah, Thierry Dencœux, and Hichem Snoussi. A dependent multilabel classification method derived from the k-nearest neighbor rule. *EURASIP Journal on Advances in Signal Processing*, 2011(1):1–14, 2011.
- [11] Min-Ling Zhang and Zhi-Hua Zhou. ML-KNN: A lazy learning approach to multi-label learning. *Pattern Recognition*, 40(7):2038–2048, 2007.



# Emerging topics and challenges of learning from noisy data in non-standard classification: A survey beyond binary class noise

Ronaldo C. Prati

*Center of Mathematics, Computer Science and Cognition  
Federal University of ABC  
Santo André, São Paulo, Brazil  
ronaldo.prati@ufabc.edu.br*

Julián Luengo

*Data Science and Computational Intelligence Institute  
University of Granada  
Granada, Spain  
julianlm@decsai.ugr.es*

Francisco Herrera

*Data Science and Computational Intelligence Institute  
University of Granada  
Granada, Spain  
herrera@decsai.ugr.es*

**Abstract**—This is a summary of our article published in *Knowledge and Information Systems* [1] to be part of the MultiConference CAEPIA'18 Key Works.

**Index Terms**—Data preprocessing, non-standard classification, noise data, multiclass classification, multi-instance learning, multi-label learning, multitask problems, ordinal classification, data streams, non-stationary environments

## I. SUMMARY

Learning from noisy data is an important topic in machine learning, data mining and pattern recognition, as real world data sets may suffer from imperfections in data acquisition, transmission, storage, integration and categorization. Indeed, over the last few decades, noisy data has attracted a considerable amount of attention from researchers and practitioners, and the research community has developed numerous techniques and algorithms in order to deal with the issue [2]–[4].

These approaches include the development of learning algorithms which are robust to noise as well as data pre-processing techniques that remove or “repair” noisy instances. Although noise can affect both input and class attributes, class noise is generally considered more harmful to the learning process, and methods for dealing with class noise are becoming more frequent in the literature [3].

Class noise may have many reasons, such as errors or subjectivity in the data labeling process, as well as the use of inadequate information for labeling. For instance, in some medical applications, the true status of some diseases can only be determined by expensive or intrusive procedures, some of which can only be carried out after a patient’s death. Another reason is that data labeling by domain experts is

generally costly, and several applications use labels which are automatically defined by autonomous taggers (e.g., sentiment analysis polarization [5]), or by non-domain experts. This approach is common in, e.g., social media analysis [5], where hashtags used by users or information provided by a pool of non-domain experts (crowdsourcing) are used to derive labels.

Even though class noise is predominant in the literature (see [2], [6] for recent surveys and comparison studies), most of the research has been focused on noise handling in binary class problems. However, new real-life problems have motivated the development of classification paradigms beyond binary classification [7]. These paradigms include ordinal class [8], multiclass [9], multilabel [10] and multi-instance [11] as well as learning from data streams and non-stationary environments [12] and joint exploiting related tasks [13]. Due to the ubiquity of noise, it is of fundamental importance to better understand the relationships and implications of class noise within these paradigms. Each paradigm has its own particularities which impose new challenges and research questions for noise handling. Although research for class noise handling in these paradigms is somewhat present in the literature, it remains quite scarce and requires general discussion of issues, challenges and research practices regarding it.

The related paper aims to discuss open-ended challenges and future research directions for learning with class noise data, focusing on the aforementioned non-binary classification domains. The main contributions of such a paper are:

- We discuss some current research, as well as the need of adaptation or development of new techniques for handling class noise within non-binary classification paradigms.
- We also discuss issues related to the simulation of noise scenarios (inclusion of artificial noise) within these paradigms, an experimental artifact frequently adopted

This work have been partially supported by the São Paulo State (Brazil) research council FAPESP under project 2015/20606-6, the Spanish Ministry of Science and Technology under project TIN2014-57251-P and the Andalusian Research Plan under project P12-TIC-2958.

for analysis of noise dealing techniques. These issues are important for simulating noise scenarios that may occur in real world applications, and can serve as the basis for uniforming procedures by providing an objective ground in order to assess the robustness of the learning methods.

- We present some important open-ended issues and offer some possible solutions to the existing problems.

We are aware of some studies already considering multiclass noise problems. Different multiclass noise patterns impose numerous challenges, some of them infrequently addressed in the literature. Even state of the art methods for dealing with binary class noise present considerable variation in performance when considering different multiclass noise patterns at the same noise ratio. Despite this, these issues are seldom considered in the literature. In the related paper we focus on some of aspects that could be studied further, providing a guideline of open challenges for researchers, such as:

- Would these different types of noise patterns pose the same or different challenges when dealing with multiple class noise?
- Which one would be more difficult to tackle?
- Which aspects of the problem would be more affected by considering different noise multiclass pattern?
- How do existing methods behave considering these different noise patterns?

One interesting topic for further research is how to extend methods, originally developed only for binary class, to the multiclass case. Some data transformation approaches for transforming multiclass to binary problems, e.g., One-versus-One (OVO) or One-versus-ALL (OVA), could be applied [14]. However, research on this topic generally involves random noise completely at random, with uniform class noise distribution. Investigating how these approaches are affected by different noise patterns is an interesting topic for research. For instance, when applying a filter using a OVA decomposition, does the order in which class noise is removed matter? If so, is this influence stronger for different noise distribution among the classes?

Another open-ended problem is the relationship with imbalanced classification [15] and multiclass noise. It is reported in the literature that noise in minority classes is more harmful than in majority classes [16]. However, multiclass imbalance [17] has further issues to consider, as multiple predominant or infrequent classes may occur. It is unclear what learning difficulties multiclass noise can cause under highly imbalanced class distributions, and how to handle it effectively is an open-ended issue. Furthermore, different noise patterns can change the observed class ratio, which may influence the behavior of class imbalance techniques. Uniform class noise, for instance, may mask the observed class ratio of multiple rare classes even for low noise levels. Default class may also introduce an artificial predominant class, thus generating an artificial imbalanced problem due to the presence of noise. Possible ways to handle noise in imbalanced problems include cost sensitive noise handling [18], [19], attributing and the

development of class ratio aware filtering approaches [20] considering the multiclass context.

We believe this discussion will encourage researchers and practitioners to explore the problem of class noise handling in new scenarios and different learning paradigms in more detail.

## REFERENCES

- [1] R. C. Prati, J. Luengo, and F. Herrera, "Emerging topics and challenges of learning from noisy data in non-standard classification: A survey beyond binary class noise," *Knowledge and Information Systems*, vol. in press, 2018.
- [2] B. Fréney and M. Verleysen, "Classification in the presence of label noise: A survey," vol. 25, no. 5, pp. 845–869, 2014.
- [3] X. Zhu and X. Wu, "Class noise vs. attribute noise: A quantitative study," *Artif. Intell. Rev.*, vol. 22, no. 3, pp. 177–210, 2004.
- [4] S. García, J. Luengo, and F. Herrera, *Data preprocessing in data mining*. Springer, 2015.
- [5] B. Liu, *Sentiment analysis: Mining opinions, sentiments, and emotions*. Cambridge University Press, 2015.
- [6] D. F. Nettleton, A. Orriols-Puig, and A. Fornells, "A study of the effect of different types of noise on the precision of supervised learning techniques," *Artif. Intell. Rev.*, vol. 33, no. 4, pp. 275–306, 2010.
- [7] J. Hernández-González, I. Inza, and J. A. Lozano, "Weak supervision and other non-standard classification problems: a taxonomy," *Pattern Recognit. Lett.*, vol. 69, pp. 49–55, 2016.
- [8] P. A. Gutiérrez, M. Perez-Ortiz, J. Sanchez-Monedero, F. Fernández-Navarro, and C. Hervás-Martínez, "Ordinal regression methods: survey and experimental study," vol. 28, no. 1, pp. 127–146, 2016.
- [9] T. G. Dietterich and G. Bakiri, "Solving multiclass learning problems via error-correcting output codes," *Journal of artificial intelligence research*, vol. 2, pp. 263–286, 1995.
- [10] F. Herrera, F. Charte, A. J. Rivera, and M. J. del Jesus, *Multilabel Classification: Problem Analysis, Metrics and Techniques*. Springer, 2016.
- [11] F. Herrera, S. Ventura, R. Bello, C. Cornelis, A. Zafra, D. Sánchez-Tarragó, and S. Vluymans, *Multiple Instance Learning: Foundations and Algorithms*. Springer, 2016.
- [12] G. Ditzler, M. Roveri, C. Alippi, and R. Polikar, "Learning in nonstationary environments: a survey," vol. 10, no. 4, pp. 12–25, 2015.
- [13] T. Evgeniou, C. A. Micchelli, and M. Pontil, "Learning multiple tasks with kernel methods," *Journal of Machine Learning Research*, vol. 6, no. Apr, pp. 615–637, 2005.
- [14] J. A. Sáez, M. Galar, J. Luengo, and F. Herrera, "Analyzing the presence of noise in multi-class problems: alleviating its influence with the one-vs-one decomposition," *Knowledge and information systems*, vol. 38, no. 1, pp. 179–206, 2014.
- [15] R. C. Prati, G. E. A. P. A. Batista, and D. F. Silva, "Class imbalance revisited: a new experimental setup to assess the performance of treatment methods," *Knowl. Inf. Syst.*, vol. 45, no. 1, pp. 247–270, 2015.
- [16] J. Van Hulse and T. Khoshgoftaar, "Knowledge discovery from imbalanced and noisy data," *Data Knowl. Eng.*, vol. 68, no. 12, pp. 1513–1542, 2009.
- [17] S. Wang and X. Yao, "Multiclass imbalance problems: Analysis and potential solutions," vol. 42, no. 4, pp. 1119–1130, 2012.
- [18] X. Zhu and X. Wu, "Cost-guided class noise handling for effective cost-sensitive learning," in *IEEE International Conference on Data Mining (ICDM)*. IEEE, 2004, pp. 297–304.
- [19] X. Zhu, X. Wu, T. M. Khoshgoftaar, and Y. Shi, "An empirical study of the noise impact on cost-sensitive learning," in *International Joint Conference on Artificial Intelligence (IJCAI)*, vol. 7, 2007, pp. 1168–1173.
- [20] J. A. Sáez, J. Luengo, J. Stefanowski, and F. Herrera, "Smote-ipf: Addressing the noisy and borderline examples problem in imbalanced classification by a re-sampling method with filtering," *Inf. Sci.*, vol. 291, pp. 184–203, 2015.



# Training Set Selection for Monotonic Ordinal Classification

José-Ramón Cano  
*Dept. of Computer Science*  
*University of Jaén*  
 Linares, Spain  
 jrcano@ujaen.es

Salvador García  
*Dept. of Computer Science and Artificial Intelligence*  
*University of Granada*  
 Granada, Spain  
 salvagl@decsai.ugr.es

**Abstract**—This is a summary of our article published in *Data & Knowledge Engineering* [1] to be part of the *MultiConference CAEPIA'18 KeyWorks*.

**Index Terms**—*Monotonic Classification, Ordinal Classification, Training Set Selection, Data Preprocessing, Machine Learning*

## I. SUMMARY

Learning with ordinal data sets has increased the attention of the machine learning community in recent years. These data sets are characterized by the presence of an ordinal output and they are commonly found in real life.

Monotonic classification is an ordinal classification problem where monotonic constraints are present in the sense that a higher value of a feature in an instance, fixing the other values, should not decrease its class assignment [2]. Monotonicity is a property commonly found in many environments of our lives like economics, natural language or game theory [4]. A classical example of monotonicity is in the case of bankruptcy prediction in companies, where appropriate actions can be taken in time, considering the information based on financial indicators taken from their annual reports. The comparison of two companies where one dominates the other on all financial indicators shows clearly where the monotonicity is present, which supposes that the overall evaluation of the second cannot be higher than the evaluation of the first. This strategy could be applied to the credit rating score used by banks as well as for the bankruptcy prediction strategy .

In the specialized literature we can find multiple monotonic classifiers proposed. As a restriction, some of them require the training set to be purely monotone to work properly. Other classifiers can handle non-monotonic data sets, but they do not guarantee monotone predictions.

In addition, real-life data sets are likely to have noise, which obscures the relationship between features and the class. This fact affects the prediction capabilities of the learning algorithms which learn models from those data sets.

This work was supported by TIN2014-57251-P, by the Spanish "Ministerio de Economía y Competitividad" and by "Fondo Europeo de Desarrollo Regional" (FEDER) under Project TEC2015-69496-R and the Foundation BBVA project 75/2016 BigDaPTOOLS.

In order to address these shortcomings and to test the prediction competences of the monotonic classifiers, the usual trend is to generate data sets which completely satisfy the monotonicity conditions. The intuitive idea behind this is that the models trained on monotonic data sets should offer better predictive performance than the models trained on the original data. In the specialized literature, we find two possible techniques to generate monotonic data sets. Monotonic data sets can be created by generating artificial data [5] and by relabeling the real data [6]. The latter restores the monotonicity of the data set by changing the class labels in those instances which violate the monotonicity constraints. Class relabeling is the only approach which can be applied in real life data sets, and has shown promising results in the literature.

As an alternative to relabel, Training Set Selection (TSS) is known as an application of instance selection methods [3] over the training set used to build any predictive model. The effects produced by TSS are: reduction in space complexity, decrease in computational cost and the selection of the most representative instances by discarding noisy ones.

In this paper we propose a TSS algorithm to manage monotonic classification problems, called Monotonic Training Set Selection (MonTSS). MonTSS can be considered as the first in the literature for performing TSS in monotonic classification problems. It is a data preprocessing technique which, by means of a suitable TSS process for monotonic domains, offers an alternative without modifying the class labels of the data set, it instead removes harmful instances. MonTSS incorporates proper measurements to identify and select the most suitable instances in the training set to enhance both the accuracy and the monotonic nature of the models produced by different classifiers.

The whole process is presented in Figure 1, and as can be seen it is composed of three stages:

- 1) The MonTSS process starts with a preprocessing step where MonTSS analyzes the original data set by quantifying the relationship between each input feature and the output class. This relation is estimated with a metric called Rank Mutual Information (RMI). With it, we

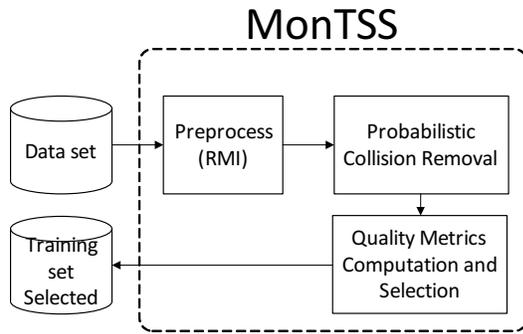


Fig. 1. MonTSS process.

know the features which have a real direct or inverse monotonic relation with the class or no relation as well (including unordered categorical features). The RMI value is evaluated in the training data set to decide which features are used in the computation of collisions between instances.

In essence, rank mutual information can be considered as the degree of monotonicity between features  $A_1, \dots, A_f$  and the feature class  $Y$ . Given any feature  $A_j$  and feature class  $Y$ , the value of RMI for the feature  $A_j$  is calculated as follows:

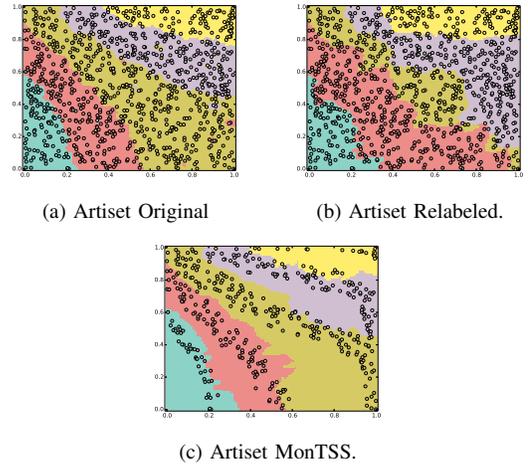
$$\text{RMI}(A_j, Y) = -\frac{1}{n} \sum_{i=1}^n \log \frac{\#[x_i]_{A_j}^{\leq} \cdot \#[x_i]_{\bar{Y}}^{\leq}}{n \cdot \#[x_i]_{A_j}^{\leq} \cap [x_i]_{\bar{Y}}^{\leq}} \quad (1)$$

where  $n$  is the number of instances in data set  $D$ ,  $[x_i]_{A_j}^{\leq}$  is the set formed by all the instances of the set  $D$  whose feature  $A_j$  is less or equal than feature  $A_j$  of instance  $x_i$ , and  $[x_i]_{\bar{Y}}^{\leq}$  is the set composed of the instances of the set  $D$  whose feature class  $Y$  is less or equal than feature class  $Y$  of instance  $x_i$ .

- 2) In the second stage, the probabilistic collision removal mechanism is applied, which eliminates most of the instances which produce collisions. The remaining instances are used as input in the last stage.
- 3) Here, the quality metrics are computed and based on them, the selection procedure is developed considering the following rule:

$$\text{Select } x_i = \begin{cases} \text{true} & \text{if } \text{Del}(x_i) < \text{Infl}(x_i) \\ & \text{or } \text{Del}(x_i) \geq 0.9 \\ \text{false} & \text{otherwise.} \end{cases} \quad (2)$$

The rationale behind this rule is to retain the instances which are closer to the class boundaries, using a straightforward threshold of 0.9 which is independent from the diversity of their neighborhood. Furthermore, a relationship between  $\text{Del}(x_i)$  and  $\text{Infl}(x_i)$  can be easily established as they represent a measurement in the same range of the relative rate of the situation and the neighborhood variety of every instance. In this respect, the rule is built as a function of both measures. As


 Fig. 2. Artificial data set (Artiset) preprocessed by Relabeling and MonTSS with the borders calculated by  $MkNN$  with 3 neighbors.

a result, for instance, the rule preserves the instances belonging to central areas if there are instances of other classes around.

We have compared the results offered by well-known classical monotonic classifiers over 30 data sets with and without the use of MonTSS as a data preprocessing stage. As graphical example of use we present the Fig. 2.

The results show that MonTSS is able to select the most representative instances, which leads monotonic classifiers to always offer equal or better results than without preprocessing.

MonTSS is able to select the most representative instances independently of the classifier to be applied later. This leads monotonic classifiers to always offer equal or better results than without preprocessing. Furthermore, data related metrics are notably improved, fully satisfying the monotonicity restrictions without affecting or modifying the nature of the original data. At the same time, it reduces the number of non-comparable pairs of instances and the size of the training data sets before the learning stage starts.

## REFERENCES

- [1] J.-R. Cano and S. García, “Training set selection for monotonic ordinal classification,” *Data & Knowledge Engineering*, vol. 112, pp. 94–105, 2017.
- [2] H. Daniels and M. Velikova, “Monotone and partially monotone neural networks,” *IEEE Transactions on Neural Networks*, vol. 21, num. 6, pp. 906–917, 2010.
- [3] J.-R. Cano, N.R. Aljohani, R.A. Abbasi, J.S. Alowidbi and S. García, “Prototype selection to improve monotonic nearest neighbor,” *Engineering Applications of Artificial Intelligence*, vol. 60, pp. 128–135, 2017.
- [4] W. Kotłowski and R. Słowiński, “On nonparametric ordinal classification with monotonicity constraints,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, num. 11, pp. 2576–2589, 2013.
- [5] R. Potharst, A. Ben-David and M.C. van Wezel, “Two algorithms for generating structured and unstructured monotone ordinal data sets,” *Engineering Applications of Artificial Intelligence*, vol. 22, num. 4-5, pp. 491–496, 2009.
- [6] M. Rademaker, B. De Baets and H. De Meyer, “Optimal monotone relabelling of partially non-monotone ordinal data,” *Optimization Methods and Software*, vol. 27, num. 1, pp. 17–31, 2012.



# Data source analysis in mood disorder research

*Pavél Llamocca Portella*

Universidad Complutense de Madrid  
[pavel.llamocca@hotmail.com](mailto:pavel.llamocca@hotmail.com)

*Milena Čukić*

University of Belgrade  
[milena.cukic@gmail.com](mailto:milena.cukic@gmail.com)

*Axel Junestrand*

Universidad Complutense de Madrid  
[axel.junestrand@hotmail.com](mailto:axel.junestrand@hotmail.com)

*Diego Urgelés*

Hospital Ntra. Sra. De la Paz  
[diego.urgeles@gmail.com](mailto:diego.urgeles@gmail.com)

*Victoria López López*

Universidad Complutense de Madrid  
[vlopezlo@ucm.es](mailto:vlopezlo@ucm.es)

**Abstract**— Mood disorders have been a relevant topic for the last few years. Nowadays, there are projects in the mental health area which are supported by technological devices that improve the efficiency of treatments by effortlessly allowing the gathering of biological and psychological indicators from patients. One of the goals of this document is to describe the most common methods for collecting most of those indicators and to study which of them can be applied to the Bip4Cast project. The purpose of this article is to analyze the sources of information that have been used successfully in the study of emotional disorders as well as alternative sources of information from the monitoring of movement and sounds in the patient's environment. This article shows the results of the analysis of traditional information sources. The results show a lack of precision in the data on fundamental variables such as sleep quality and motor activity. Therefore, the study demonstrates the need to include new sources of information to increase the quality of the data before applying crisis prediction algorithms. The need to monitor the sleep and movement of patients in order to achieve a sufficient quality in the source data from the evolutionary analysis of patients is concluded.

**Keywords**—*bipolar disorder; mood disorder; data gathering; machine learning; data analysis.*

## I. INTRODUCTION

The quality of treatments in mood disorders has acquired a high attention for researchers in the mental health field. However, despite current efforts, there is still plenty of room for improvement. Many practitioners agree that knowing how patients react to treatments in advance and predicting when their mood could vary significantly are two of the most important issues to solve in order to ensure the quality of new treatments.

The proposal of the Bip4Cast project is to keep using the current monitoring of personal sessions between patients and psychiatrists, but also to add new data sources and their analysis to improve the prediction of Bipolar Disorder crises in patients. The main idea is to get advantage of the new developments in data gathering, data cleaning, and Machine

Learning to monitor a set of patients and make a new approach with these data. The patients are encouraged to follow certain methods for gathering psychological and biological indicators during a particular period of time. The goal is to analyze the data gathered in order to find some common patterns that could trigger a crisis. For the process of pattern detection, some Machine Learning tools and mathematical models are being used.

The goal of this document is to cover a discussion about some methods for gathering indicators and the feasibility of their usage in this project. Apart from this introduction, this document includes the following sections: section 2 presents the state of the art related research in mood changes and patient monitoring. In section 3, several methods for gathering psychological and biological parameters are described. Section 4 covers the preliminary analytics on the Bip4Cast data sets and, finally, section 5 includes the conclusions.

## II. STATE OF THE ART

Several studies about Bipolar Disorder state that a relationship exists between the different behaviors of the patients before the occurrence of a crisis [1-2]. For example, during a manic or a depressive crisis, some of these studies agree that sleeping rates are very important indicators. Vocal features as well as the rate of speech are other important indicators and there are some studies stating that the pitch is lower in a depressed state [3]. Also, parameters like the time of exposure to dark or sunny places and the physical activity are considered.

In [4], the author introduces a mobile health system using several sensors for mood detection. In [5], the author presents a research that includes Machine Learning models in a mobile application in order to estimate the mood in depressive patients. However, no objective psychological or psychiatric markers are considered due to the recording of the data being done manually by patients. Furthermore, there is an interesting study which describes the use of electroencephalography for the gathering of brain signals. It also uses non-linear features

like Higuchi's Fractal Dimension and Sample Entropy to feed different Machine Learning methods [6]. In [7], a mobile application is presented for supporting the treatments of patients with Bipolar Disorder. Its key is to compare objective and subjective data. It records objective data using some features given by mobile phones like accelerometers and phone call rates. This information is used for predicting trends in the mood of the patients. However, the focus of this application is to record subjective data using a self-reporting approach.

At the present time, there are some projects within the scope of mental health which have similar approaches and try to obtain certain markers from which a common pattern can be inferred to help with the treatments. One of these projects is PSYCHE [8], whose main idea is for the patients to use a special garment made of a proper material, of which the main goal is to collect parameters from the patient in his/her daily life. The outcomes of PSYCHE are positive. However, patients said that the main inconvenient was to use the same clothes all the time, which implicates a high discomfort for the patient and therefore its non-use. Another really interesting project is MONARCA [9]. It emphasizes the use of mobile phones for the electronical monitoring of patients. The number of parameters that can be obtained through the use of a mobile phone is really high, but nevertheless, none of them are physiological parameters. Furthermore, after 3 years of activity with this application, an analysis of some non-functional requirements for the treatment of patients with Bipolar Disorder concluded that, for new developments, some details have to be taken into consideration in order to improve the ease of use, e.g.: ensuring that the patients have a data plan for their 3G connection, the need for teaching the clinicians how to operate the system, and the overheating of the smart phone from the use of an application that requires both GPS and Bluetooth.

Since few years ago, Body Sensor Networks (BSN) have made an appearance, which are a branch of wireless sensor networks (WSNs) that conform one of the core technologies of IoT developments in the healthcare system [10]. Its purpose is to provide an integrated hardware and software platform which facilitates the future development of pervasive monitoring systems. BSN allow the monitoring of patients by using a collection of tiny-powered and lightweight wireless sensor nodes. These nodes are placed on the skin and sometimes integrated with different garments, so that the patient's health-related data can be collected and transferred to the healthcare staff in real time. However, the development of this new technology in healthcare applications without considering security makes patient privacy vulnerable. For this reason, several research projects are currently being carried out to try to cover this vulnerability [11].

### III. DATA SOURCE ANALYSIS

All the research that is currently being conducted suggests a wide variety of indicators for taking mood disorder treatments into account. The indicators themselves and the way in which they are collected are strongly related. In this section, several data sources for gathering those indicators are described. Depending on the indicator they gather or the type of device, they are classified into 6 groups as shown below.

**1. Smart wristband/smart band.** These devices include a set of sensors which measure daily activity by means of accelerometers. They create variables such as an activity tracker (resting, moving or sleeping), a pedometer (steps taken and distance traveled), the calories burned, a sleep monitor (awake, slight and deep sleeping), the heart rate and the blood oxygen level. The most relevant variable measured from this type of device is the sleep indicator. Almost all researchers agree that sleep quality is the best indicator in Bipolar Disorder treatments. The CHOICE [12] study states that lower levels of depression are correlated with improvements in insomnia treatments, and on the other hand, high levels of mania are correlated with less need for sleep. Furthermore, a pilot randomized controlled trial demonstrated that sleep disturbance appears to be an important pathway contributing to Bipolar Disorder [13]. These data can easily be gathered from popular apps. Fig. 1 (a) shows one of the monitors used in the Bip4Cast project.



Fig. 1. Two sleep monitors in Bip4Cast (a- Garmin Vivofit3; b- Sleep Cycle for iPhone)

**2. Medical bands.** They allow measuring more parameters because they usually include more hardware and better features like atmospheric pressure (barometer), GPS location and magnetometer. There is some research which links episodes to disturbances in circadian rhythms and lifestyle regularity. Those indicators can be collected through these devices using the activity tracker or gyroscope. Furthermore, this research suggests that methods for tracking behavior, nutrition, blood pressure and lipid profile as well as physical/social activity and sleep-awake routines may improve treatments. In the Bip4Cast project we are using GENEActiv v.1.2 for a total of 25 patients, (see [14] for more details about their use in Bip4Cast).

**3. Mobile Sensors.** In this group, any other kind of sensors that can be worn by the user on any other part of the body is included, e.g. for wearing on the leg, ActivPAL is a kind of device used to investigate the correlation between physical behaviors and chronic disease [15]. For using as a necklace, LeafUrban is an option (there are some versions for wearing on the wrist or attached to the clothes). It is a device designed for women and what it makes different from other devices is the tracking of the menstrual cycle, the fertility and the breathing [16]. For wearing on the head, ELF Emmit is a headband that helps the user improve the state of both mind and body by



using pulsed electromagnetic stimulation (PEMS) [17]. Relevant variables include skin and breath changes, electrocardiogram and respirogram data, stress level and menstrual cycle among others.

**4. Sleep Activity Recording Devices.** In this group, any device specialized in recording sounds and activities during sleep is included. There are hundreds of mobile applications that record sounds during sleep. One of the main objectives is to detect snoring, for which four of the most popular applications at the moment are SleepGenius, SleepCycle (see Fig. 1 (b)), SleepBot and SleepTime. However, there are other kinds of devices with different non-invasive designs, e.g. devices attached to the mattress which can track sounds as well as heart rate, breathing, movement, etc. The reason for using these methods is to improve sleeping conditions. Almost all of these methods have one parameter in common: “breathing”, which allows the detection of snoring. Habitual snoring is a prevalent condition that is not only a marker for Obstructive Sleep Apnea (OSA) but can also lead to vascular risks [18]. Some researchers have found a relationship between OSA and Major Depressive Disorder/Bipolar Disorder.

**5. Forms and Questionnaires.** This group contains any method which uses a questionnaire or a form for the self-reporting of mood. In current literature, these methods were designed by psychiatrists and are presented as scales. There are several scales for detecting the risk of a euphoria episode outbreak: Altman Self-Rating Mania Scale (ASRM) [19], the Clinician-Administered Rating Scale for Mania (CARS-M), the Internal State Scale (ISS), the Self-Report Manic Inventory (SRMI), etc. For depression episodes, there are several scales, like the Patient Health Questionnaire (PHQ-9) [20]. All of them consist in questionnaires which can be performed by patients. This presents the opportunity of developing digital forms based on these patients in order to facilitate their use.

Scales for detecting the risk of euphoria or mania episodes, like the Young Mania Rating Scale (YMRS) and the Bech-Rafaelsen Mania Scale (MAS), or the Hamilton Depression Rating Scale (HDRS), which detects the risk of depression, are not included because they are performed by the clinician (however, for the scope of this project, these scales are included in normal monitoring sessions). All of these questionnaires collect variables from which it is possible to measure the presence and severity of mania, depression, affective, psychological and somatic symptoms. Fig. 2 shows the interface of an application developed for collecting these data. All the details about this work are in [21].

**6. Mobile Apps / Time Consumption.** This group includes mobile applications that support BPD treatments and/or record smart phone use. For the aim of this project, these mobile applications were classified into two subclasses: the first one, named Bipolar Disorder Apps (BPDA) in this document, includes any applications that have been developed for supporting the treatment itself, and the second one, named Time Consumption Apps (TCA) in this document, includes any application that is able to measure the time spent using a specific mobile application.

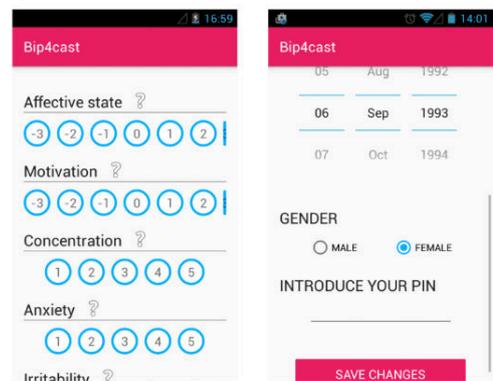


Fig. 2. First version of the app for collecting daily personal data

**7. Conventional methods.** Finally, patients are also being assessed periodically through interviews. This evaluation is done by psychiatrists in medical centers. For the patient, this does not imply any kind of alteration in the current treatment. However, the procedure will need the psychiatrist to send the collected data from those sessions to the data server. It is important to mention that in this phase, the Young Mania Rating Scale (YMRS) and the Hamilton Depression Rating Scale (HDRS) are included for detecting mania or depression episodes.

Also, psychiatrists can take advantage of these interviews for downloading the data recorded from wristbands and medical bands in order to later send them to a dedicated server (just in case these devices are not able to send the recorded data automatically).

#### IV. THE BIP4CAST PROJECT

Patients with Bipolar Disorder are characterized by a behavior which is difficult to predict. There is great deal of information which can be retrieved from biological, physiological and physical signals in order to detect episodes. Knowing which variables are correlated and which features or parameters are important is essential to build a model that will successfully predict the target of a study. The aim of this study is to investigate which features have the highest importance in health. In order to achieve this, Machine Learning algorithms and techniques are used for feature ranking.

The data used for this project is anonymized patient data gathered by psychiatrists at Clínica Nuestra Señora de la Paz in Madrid. All the data were available in an Excel file with different sheets. Even though 25 patients are already wearing a medical band (GENEActiv 1.2) and we have developed an application for gathering their daily activity, for this study most of the data have been gathered in a supervised manner during medical appointments with four different patients that suffer from Bipolar Disorder. The goal for the future is that these data are both recorded by the psychiatrists in appointments and with the help of mobile applications. This way, the patients can actively participate in their own diagnosis. The data consist of 4 data sets: Episodes, which represents different episode periods in the patients (depression/mania) from a total of four

patients; YMRS data set, which contains Young Mania Rating Scale [22] data (to assess mania symptoms) from a total of 48 days; HDRS data set, which contains Hamilton Depression Rating Scale [23] data (for depression), also from a total of 48 days; Interview data set, which contains 728 registers about physical and psychological items, the latter including variables like anxiety, irritability or concentration problems, and the former including more objective data, as could be the number of cigarettes smoked by the patient or the time in which the patient woke up or went to bed. The last data set used in the study is Interventions. It includes data about all the medical interventions that different doctors have had with the patients, in a total of 92 registers. For the gathering of data included in the Interview data set, a mobile application [21] has been developed, which patients can use daily to store quantitative data (number of cigarettes, menstruation, etc.) and qualitative data (feeling of stress, anxiety, etc.). In the project, we have also included studies with data from a medical bracelet (GENEActif 2.1 for 25 patients) and an application for recording night sounds. The data collected by these last two exercises will be included in subsequent studies.

The programming language used in this project is Python 2.7, which has a lot of libraries that make data cleaning and visualization less complicated, as well as applying Machine Learning algorithms. The environment used is Jupyter Notebook [24]. Scikit-learn [25] is the Machine Learning library of choice for this project because it includes preprocessing and cross-validation tools as well as all the known baseline Machine Learning algorithms. This project is shared in a public GitHub repository, which can be found at [26].

#### A. Data Cleaning

The first step of the project consisted in the data cleaning which included the gathering of the data that we would be working with. In order to gather the data, we exported each sheet, from the Excel file that was given to us by the hospital, to csv format. The initial Excel file was divided into five different sheets: Episodes, YMRS, HDRS, Interview Data Set (IDS) and Interventions. In order to export them to a format readable by Pandas [27], we saved each sheet as CSV UTF-8 in Microsoft Excel. Some other improvement was done in relation to data cleaning: filling the empty values, converting them from Float to Integer and data type revision.

#### B. Exploratory Data Analysis

After the data cleaning, we performed an Exploratory Data Analysis, in order to visualize how the data behaved. We used histograms, heatmaps and scatterplots in this part. For instance, the YMRS data set correlation heatmap showed that aggressiveness and verbal expression were correlated. This could mean that if the patient talks a lot (excessive speech rate), this behavior would probably be accompanied by excessive energy or hyperactivity (Disruptive-Aggressive Behavior). The scatterplot matrix from the YMRS data showed that hyperactivity and irritability have a similar distribution as well as a correlation between verbal expression and euphoria. The HDRS data set analysis showed a similar distribution between suicide and precocious insomnia (difficulty of sleep early in the

night). The HDRS data set correlation heatmap showed a high correlation between depressed mood and work: the less a patient is willing to work or do other activities, the more depressed he or she will probably feel. At this stage of the research, the best data set regarding both size and accuracy was the Interview Data Set (IDS). During its analysis, we found a clear linear relationship between the variables mood and motivation. The Intervention data set presented a lack of correlation between the level of relief in a patient and the GAF (Global Assessment of Functioning). A good summary of all these results can be read at [26].

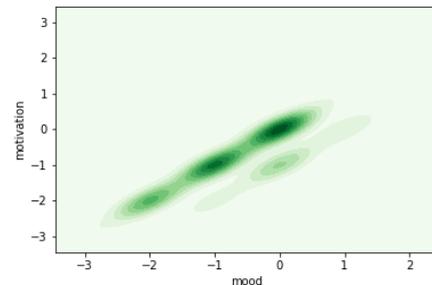


Fig. 3. 2D kernel density plot of mood and motivation in Interview data set

#### C. Data Combination

The goal of this phase was to find data set combinations that had enough data for the algorithms to process so that we could later see which data sets returned the highest accuracy. In order to get the combinations right, we defined a function that obtained the date of each entry and compared it with the different episodes of depression and mania in the Episode data set, which was the target of the prediction. For the entries or rows that were not recorded in the Episode data set, we assumed that the patient was in a euthymic state. This way, we got three possible states that a patient could be in: Depression (D), Mania (M) and Euthymic (N). For instance, with the HDRS and Episode combination we could see that when the patients had a depression episode, the value of depressed mood was much higher, almost always between 2 and 3, which meant that they either spontaneously reported feeling depressed or they communicated feeling depressed in a non-verbal way, judging by the rating items from the Hamilton Depression Rating Scale (HDRS). We could also see that when the patients were in a depression state (because of the predominance of green points on higher values of the work axis, where green represented patients in a state of depression), they started feeling loss of interest in activities they usually performed or there was a decrease in the time spent on work and other activities, which made perfect sense according to this rating scale.

#### D. Application of the Algorithms

The data sets on which we tested the algorithms were: YMRS (Young Mania Rating Scale data), HDRS (Hamilton Depression Rating Scale data), Interviews (interview data, IDS), Interventions (intervention data), YMRS-HDRS (combination of the YMRS and HDRS data) and Interviews-Interventions (combination of the Interview and Intervention

data). Fig.4 shows the diagram of the process followed during this study.

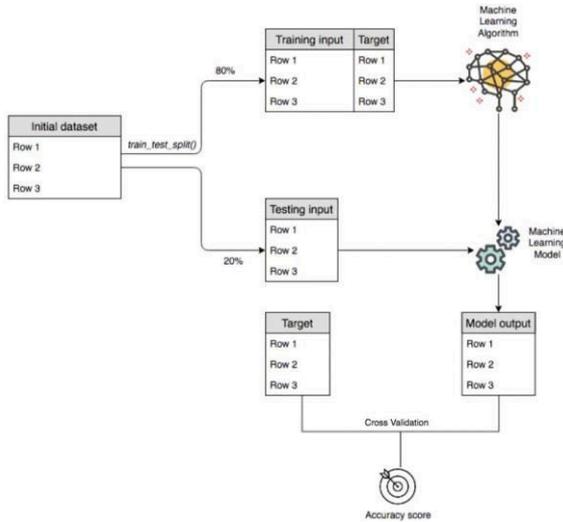


Fig. 4. Diagram of the Machine Learning algorithm application process

The algorithms that we used for this part were: Decision Tree [27], Random Forest [28], Support Vector Machines [29] and Logistic Regression [30]. The reason why these algorithms have been chosen for this project is explained in [26], in the section belonging to each algorithm.

The fact that these algorithms have been applied in this project does not mean that they are the best option for the classification of Bipolar Disorder states, but rather that they are the most suitable ones given the amount of data and the number of features used for the project. In future studies that make use of this project, if the data sets are larger it could be interesting to apply other algorithms too, like the Naïve Bayes [31] algorithm or any kind of Boosting algorithm [32], as to see how they perform on this particular classification problem.

Before applying each algorithm, as is necessary for every classification problem, the original data needed to be split into training and testing sets. Later, the training data would be used to train the prediction models and the testing data would be used to compare the output of the model with the real targets by cross-validation, a technique presented first by M. Stone in 1974 [33], that is used widely in Machine Learning for algorithm performance comparison.

The testing set is used for obtaining the accuracy of the model, as mentioned above, which is done by comparing the output obtained from the testing input and the real output of the testing set. In order to divide the original data sets into training and testing sets, we used the `train_test_split()` function from the scikit-learn library [25], where the test size represents the percentage of the data that is used for the testing set. After the algorithms were applied, the `cross_val_score()` function, which is also included in the scikit-learn library, was called in order to evaluate the score by k-fold cross-validation [33].

The best way to compare the accuracies obtained with the different algorithms on all the data sets was to make an algorithm performance matrix, which is shown in Table 1. This

matrix showed that, in average, the data set that returned the best prediction accuracy (69%) with the algorithms was the Interview data set, as seen on the right column. The algorithm that performed the best, also in average (62%), was the Logistic Regression algorithm, as seen on the column farthest down.

Even though the algorithm that had the best accuracy average was the Logistic Regression, we stated that the Random Forest algorithm made the most accurate predictions in the sense that they were very reasonable given the behavior of the patients, which we tested with randomized data. These predictions made possible the implementation of a small program with the Random Forest classifier that we obtained, and which can be seen in [26].

TABLE I. ACCURACIES WITH DIFFERENT ALGORITHMS

Algorithms/Datasets	Decision Tree	Random Forest	SVM	Logistic Regression	Average
YMRS	36%	38%	38%	76%	47%
HDRS	78%	55%	36%	62%	58%
Interviews	70%	72%	68%	67%	69%
Interventions	44%	65%	57%	51%	54%
YMRS-HDRS	63%	63%	70%	33%	57%
Interviews-Interventions	67%	17%	42%	83%	52%
Average	60%	52%	52%	62%	

## V. CONCLUSIONS AND FUTURE WORK

Having a deep understanding of the data is essential in any Machine Learning project focused on a branch of medical science like psychiatry, where knowing which behaviors are normal and abnormal in the patients can help us create much more precise prediction models. The amount of data used and the nature of the data source are very important factors because with a larger suitable amount of data we will be able to get prediction accuracies with a much higher level of confidence. In the same way that understanding the data is important, having a deep perception of the theory behind each algorithm used, as well as their many implementations, is crucial in order to get the models to perform in the best possible way.

In this project, several groups of data collected in a supervised way have been analyzed and a set of Machine Learning algorithms has been applied. The results allow us to make decisions about the new sources of relevant information to be incorporated in consequent studies. It is concluded that the data from sleep and daily activity, measured both by movement and sounds, are relevant for improving the prediction of a crisis in patients with Bipolar Disorder. Therefore, a future project that includes group 1 bracelets instead of the current medical wristbands is proposed, because the latter are too expensive and invasive, and the development of a new mobile application that, in addition to the daily data, includes sensitization data and sounds. Future work will also analyze the EEG data collected during supervised monitoring for the purpose of performing a comparative analysis. The implementation with Jupyter will also allow us to perform the same studies on larger databases when the number of patients in the experiment is higher.

The most immediate use of the results obtained in this project would be to train the same algorithms used but with

larger amounts of data, in order to see if they perform in a similar way. Gathering objective data from devices like phones or wristbands is something that can be accomplished quite easily according to the work already done in this sense. The goal of this task would be to compare the performance of different algorithms on the objective data gathered from these devices with the performance results obtained on the subjective data used in this project.

As for other more indirect applications of the results obtained during this project, the implementation of a drug recommending system for patients with Bipolar Disorder could be made by predicting the states in which the patients are during a certain period of time. These predictions could be stored in a database which also contains the medicine that these patients have been prescribed with during the same period of time, thus providing the possibility of seeing how each patient reacts to the different types of drugs used.

#### REFERENCES

- [1] N. Vanello et al., "Speech analysis for mood state characterization in bipolar patients," Annual International Conference of the IEEE Engineering in Medicine and Biology Society, San Diego, CA, pp. 2104-2107, 2012
- [2] T. Beiwinkel, et al. "Using Smartphones to Monitor Bipolar Disorder Symptoms: A Pilot Study". Eysenbach G, ed. JMIR Mental Health. 2016.
- [3] MN. Burns, et al., "Harnessing Context Sensing to Develop a Mobile Intervention for Depression". J Med Internet Res 2011;13(3):e55.
- [4] M. Cukic, et al. "EEG machine learning with Higuchi fractal dimension and Sample Entropy as features for successful detection of depression" CoRR abs/1803.05985 (2018): n. pag..
- [5] M. Frost, A. Doryab, M. Faurholt-Jepsen, L. Vedel Kessing, and J. E. Bardram. "Supporting disease insight through data analysis: refinements of the monarca self-assessment system". In Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing (UbiComp '13). ACM, New York, NY, USA, pp. 133-142, September-2013
- [6] H. Javelot, et al., "Telemonitoring with respect to Mood Disorders and Information and Communication Technologies: Overview and Presentation of the PSYCHE Project", BioMed Research International, vol. 2014, Article ID 104658, 12 pages, 2014.
- [7] O. Mayora, et. al., "Mobile Health Systems for Bipolar Disorder: The relevance of Non-Functional Requirements in MONARCA Project". IGI International Journal of Handheld Computing Research (IJHCR). 10.4018/978-1-4666-8756-1.ch070.
- [8] Z. Guan, T. Yang, X. Du and M. Guizani, "Secure data access for wireless body sensor networks," 2016 IEEE Wireless Communications and Networking Conference, Doha, pp. 1-6. 2016.
- [9] P. Gope and T. Hwang, "BSN-Care: A Secure IoT-Based Modern Healthcare System Using Body Sensor Network," in IEEE Sensors Journal, vol. 16, no. 5, pp. 1368-1376, March, 2016.
- [10] L. Sylvia, et. al., "Sleep disturbance may impact treatment outcome in bipolar disorder: A preliminary investigation in the context of a large comparative effectiveness trial", Journal of Affective Disorders, Volume 225, 2018, Pages 563-568, ISSN 0165-0327.
- [11] AG. Harvey, et. al., "Treating Insomnia Improves Mood State, Sleep, and Functioning in Bipolar Disorder: A Pilot Randomized Controlled Trial". Journal of consulting and clinical psychology. 83. 10.1037/a0038655.
- [12] J. Anchiraco, "Diseño de una Arquitectura Big Data para la Predicción de Crisis en el Trastorno Bipolar", Trabajo Fin de Master en Ingeniería Informática, ePrints-UCM, Madrid, 2016.
- [13] ActivePAL (2018). Retrived from <http://www.palt.com/>.
- [14] Bellabeat – Urban Collection, Health Trackers (2018). Retrieved from <https://webshop.bellabeat.com/pages/leaf-urban>
- [15] ELF Emmit Device from NewMed (2018). Retrieved from <https://www.news-medical.net/ELF-Emmit-Device-from-NewMed>
- [16] H. Nakano, et al. "Monitoring Sound To Quantify Snoring and Sleep Apnea Severity Using a Smartphone: Proof of Concept." Journal of Clinical Sleep Medicine : JCSM : Official Publication of the American Academy of Sleep Medicine 10.1 (2014): pp. 73–78, PMC. Web. 12 June 2018.
- [17] The Altman Self-Rating Mania Scale (2018). Retrieved from <https://psychology-tools.com/altman-self-rating-mania-scale/>
- [18] The Patient Health Questionnaire (PHQ-9) (2018). Retrieved from <https://patient.info/doctor/patient-health-questionnaire-phq-9>
- [19] A. Martínez, "Introduction to Big Data and First Steps in a Big Data Project", Trabajo Fin de Doble Grado Matemáticas-Informática, ePrints-UCM, Madrid, 2016.
- [20] R.C. Young et al., "A rating scale for mania: reliability, validity and sensitivity", British Journal of Psychiatry, 1978
- [21] M. Hamilton, "A rating scale for depression", Journal of Neurology, Neurosurgery, and Psychiatry, 1960.
- [22] F. Perez and B. E. Granger, "IPython: A System for Interactive Scientific Computing," in Computing in Science & Engineering, vol. 9, no. 3, pp. 21-29, May-June 2007.
- [23] F. Pedregosa et al., "Scikit-learn: Machine Learning in Python", Journal of Machine Learning Research 12 (2011), pp. 2825-283. November, 2011.
- [24] A. Junestrand, "Application of Machine Learning Algorithms for Bipolar Disorder Crisis Prediction", Trabajo Fin de Grado Ingeniería Informática, ePrints-UCM, Madrid, 2018.
- [25] W. McKinney, "Data Structures for Statistical Computing in Python", Proceedings of the 9th Python in Science Conference, 2010.
- [26] T. Hastie, R. Tibshirani and J. Friedman, "The Elements of Statistical Learning", Springer Series in Statistics, 2009.
- [27] Garima, H. Gulati and P. K. Singh, "Clustering techniques in data mining: A comparison", New Delhi: 2015 2nd International Conference on Computing for Sustainable Global Development (INDIACom), 2015.
- [28] J. R. Quinlan, "Induction of Decision Trees", Hingham, Massachusetts: Kluwer Academic Publishers, 1986.
- [29] L. Breiman, "Random Forests", Berkeley, California: Statistics Department Technical Report, 2001.
- [30] C. W. Hsu, C. C. Chang and C. J. Lin, "A Practical Guide to Support Vector Classification", Taipei: National Taiwan University, 2003.
- [31] C. Y. J. Peng, K. L. Lee and G. M. Ingersoll, "An Introduction to Logistic Regression Analysis and Reporting", Bloomington, Indiana: The Journal of Educational Research, 2002.
- [32] T. Patil and S. Sherekar, "Performance Analysis of Naive Bayes and J48 Classification Algorithm for Data Classification", International Journal Of Computer Science And Applications , 2013.
- [33] P. Bühlmann and T. Hothorn, "Boosting Algorithms: Regularization, Prediction and Model Fitting", Zürich: Seminar für Statistik, ETH Zürich, 2007.
- [34] M. Stone, "Cross-validatory choice and assessment of statistical predictions", London: Royal Statistical Society, 1974.

**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 6:  
PROBLEMAS NO ESTÁNDAR







# JCLAL 2.0: mejoras y nuevas funcionalidades en la herramienta Java de código abierto para el aprendizaje activo

Eduardo Pérez  
Instituto Maimónides de Investigación  
Biomédica de Córdoba  
Email: eduardo.perez@imibic.org

Luis D. González  
Dpto. de Informática  
Universidad de Holguín  
Email: ldgonzalezo@uho.edu.cu

Luis M. Sánchez  
Dpto. de Informática  
Universidad de Holguín  
Email: lsanchezv@uho.edu.cu

Oscar Reyes  
Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Email: ogreyes@uco.es

Sebastián Ventura  
Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Email: sventura@uco.es

**Resumen**—El aprendizaje activo tiene como objetivo la construcción de mejores clasificadores mediante el etiquetado iterativo de conjuntos de ejemplos no etiquetados. Este paradigma de aprendizaje resulta de suma importancia en la actualidad, debido principalmente al alto coste que tiene el proceso de clasificación de grandes volúmenes de datos. JCLAL es una librería Java de código abierto para la investigación en el área de aprendizaje activo, que fue creada con el objetivo de facilitar el desarrollo de algoritmos y la ejecución de experimentos en esta área de estudio. En este trabajo, se presentan las mejoras y nuevas funcionalidades que incorpora JCLAL en su versión 2.0. Esta nueva versión tiene varias características que hacen de JCLAL una herramienta más potente para la investigación en el área del aprendizaje activo. Se introduce un entorno visual que facilita aún más el uso de JCLAL por usuarios no expertos en el dominio. Además, esta nueva versión aprovecha los beneficios de la computación paralela y distribuida, posibilitando que JCLAL sea utilizado eficientemente en entornos actuales donde se manejan grandes conjuntos de datos.

## I. INTRODUCCIÓN

El aprendizaje supervisado tiene como objetivo la construcción de modelos a partir de datos que han sido etiquetados previamente. Sin embargo, uno de los principales problemas de este paradigma de aprendizaje es que generalmente se requiere de una considerable cantidad de datos etiquetados para lograr construir modelos con una alta precisión. El etiquetado de datos no es una tarea sencilla de hacer, ya que requiere comúnmente un esfuerzo considerable por parte de los expertos que etiquetan los datos. En consecuencia, hoy en día se pueden encontrar muchas colecciones de datos que tienen un número reducido de ejemplos etiquetados en conjunto con una cantidad enorme de ejemplos que quedaron sin etiquetar [1]. En este tipo de escenario las técnicas supervisadas son insuficientes al no ser capaces de explotar la información útil que se encuentra implícita en los datos no etiquetados. Ante este tipo de problema, surge el aprendizaje semi-supervisado y el aprendizaje activo (AL), que tienen como principal objetivo

la construcción de modelos precisos usando tanto los datos etiquetados como los no etiquetados.

Los métodos de AL emplean como principal hipótesis que si el algoritmo tiene la oportunidad de elegir los datos para el proceso de aprendizaje, entonces se podrán construir mejores modelos con un menor costo. Las técnicas de AL tratan de superar los obstáculos del etiquetado de datos mediante consultas donde se intenta descubrir aquellos ejemplos no etiquetados que pueden aportar información útil en la construcción de un modelo. Los métodos de AL son iterativos, donde en cada paso los ejemplos no etiquetados más significativos son presentados a un oráculo (por ejemplo, un experto), el cual los etiqueta y posteriormente estos ejemplos son incorporados al conjunto de entrenamiento a partir del cual se construye un nuevo modelo. De esta manera se intenta construir un modelo más preciso usando la menor cantidad posible de información [2, 3].

En la actualidad, el rápido y adecuado desarrollo de un área de investigación está condicionado a contar con las herramientas computacionales que provean, al menos, las siguientes funcionalidades: (I) la disponibilidad de un API que permita reducir el tiempo en la implementación de nuevos algoritmos; (II) la facilidad de reproducción de experimentos; y (III) que tenga implementado un número considerable de métodos del estado del arte, de manera que le ahorre tiempo a los investigadores, así como disminuya la posibilidad de cometer errores en la implementación de dichos algoritmos. En este sentido, el AL ha estado bastante limitado, ya que las herramientas computacionales para la investigación en esta área son muy escasas, y la mayoría de las existentes no proveen de las funcionalidades mencionadas anteriormente. Entre las librerías que podemos encontrar en Internet destacan LibAct [4] desarrollada en Python, y JCLAL [5] que está completamente desarrollada en el lenguaje Java.

Si comparamos estas dos librerías de clases, es de destacar que JCLAL contiene todos los elementos tratados en LibAct,

pero además incorpora un amplio conjunto de funcionalidades que permiten controlar todo el ciclo de AL a través de un correcto y flexible diseño de clases e interfaces. De esta manera, la implementación de nuevas estrategias de AL, así como la definición de nuevos escenarios de consulta, tipos de oráculos, condiciones de paradas, entre otras muchas funcionalidades, resulta un proceso bastante sencillo de hacer. Por otra parte, JCLAL cuenta con una detallada documentación y un conjunto amplio de ejemplos.

Como parte de la evolución a la cual está sujeto cualquier software, la librería JCLAL se ha seguido mejorando y desarrollando desde su publicación inicial. El objetivo del presente trabajo es presentar las nuevas características y funcionalidades que podemos encontrar en la nueva versión de este framework. Si se analiza la versión 1.0 de JCLAL, esta no disponía de una interfaz de usuario, obligando a los investigadores a usar el sistema de configuración de experimentos (basado en ficheros XML) o bien a codificar directamente los procedimientos usando su API. En este sentido, la nueva versión de JCLAL dispone de una interfaz de usuario que lo convierte en un producto más asequible y usable, lo que posibilita conocer sus potencialidades sin tener que entrar en el proceso de asimilación de su API. Por otra parte, la antigua versión de JCLAL está limitada a trabajar solamente con conjuntos de datos que pueden ser cargados en la memoria de estaciones de trabajo individuales, lo cual complicaba el uso de este framework en escenarios con enormes volúmenes de datos (problemas *Big Data*). En este trabajo, se explica además como la nueva versión de JCLAL supera esta última limitación gracias al desarrollo de un módulo que se integra con el conocido framework para procesamiento de datos masivos Apache Spark [6].

El resto de este trabajo se organiza de la manera siguiente. En la Sección II se detallan los cambios y nuevas funcionalidades en el API de JCLAL, así como se describe la nueva manera en la que se gestiona la modularidad del framework. En la sección III se introduce el entorno visual de JCLAL, detallando las funcionalidades del mismo. La integración de la librería con el framework Spark se explica en la Sección IV. Finalmente, en la Sección V se presentan las conclusiones del presente trabajo.

## II. ESTRUCTURA DE CLASES Y NUEVAS FUNCIONALIDADES EN EL API DE JCLAL 2.0

Desde su primer lanzamiento JCLAL ha continuado mejorándose y desarrollándose como parte del proceso de actualización y mantenimiento de cualquier software. En su versión 2.0, JCLAL cuenta con una nueva estructura de clases y funcionalidades que lo convierten en un framework cada vez más cercano a los estándares que se esperan de este tipo de herramienta computacional.

Una de las nuevas funcionalidades es la posibilidad de aprovechar todas las capacidades de cómputo de las máquinas modernas. El AL es un proceso iterativo, donde en cada iteración comúnmente los pasos más costosos son la construcción del modelo, la evaluación del modelo y el cálculo de la

importancia de cada instancia no etiquetada según la estrategia de consulta. JCLAL brinda la posibilidad de paralelizar el experimento en una estación de trabajo individual y también a través del framework Apache Spark. El investigador además tiene la posibilidad de elaborar sus propias estrategias de paralelización a través de la interfaz *IParallelContext*. Si el usuario desea hacer la paralelización de forma personalizada deberá registrar su clase en un archivo de configuración, como se muestra en el ejemplo siguiente:

```
<query-strategy type="...EntropySamplingQueryStrategy">
  <parallel-unlabeled type="...TestUnlabeledDataSinglePC"/>
  <wrapper-classifier type="...WekaClassifier">
    <parallel-test type="...WekaTestModelSinglePC"/>
    <parallel-build type="...WekaBuildClassifierSinglePC"/>
    <classifier type="weka.classifiers.functions.SMO"/>
  </wrapper-classifier>
</query-strategy>
```

Anteriormente, JCLAL estaba restringido al uso de conjuntos de datos que siguieran el formato establecido por el popular framework Weka [7]. En esta nueva versión, se modificó la jerarquía de clases e interfaces que están relacionadas con la manipulación de los conjuntos de datos. De esta manera, se logra una mayor flexibilidad e independencia en el trabajo con los conjuntos de datos, haciendo posible integrar a JCLAL con datos en formato de cualquier otro framework. Si un investigador quiere aplicar JCLAL en conjuntos de datos no soportados nativamente, solamente tendrá que implementar las interfaces *Instance* e *IDataset*; además estas interfaces dan soporte a los tipos de instancias densas y dispersas.

Por otra parte, en JCLAL 2.0 se le ha dado mayor soporte a los clasificadores del framework MOA [8], lo cual permite utilizar algoritmos de aprendizaje incremental en el proceso de AL. De esta manera, el modelo no necesita ser entrenado desde cero en cada iteración de AL (a diferencia de la mayoría de los clasificadores de Weka), lo cual mejora significativamente el rendimiento en escenarios donde se disponen de grandes volúmenes de datos no etiquetados o con datos en *streaming*.

Por último, en esta nueva versión se ha añadido un paquete de clases que implementan varios test estadísticos no paramétricos. Dicho paquete está inspirado en el módulo de test estadísticos de la librería Keel [9]. Los test estadísticos son de suma importancia para el análisis de resultados experimentales, y JCLAL incluye varios test que permiten realizar comparaciones múltiples entre estrategias de AL.

### II-A. Modularidad de JCLAL

Una de las nuevas mejoras es la modularidad del framework, lo cual facilita su portabilidad y distribución. La idea surgió al observar que JCLAL crecía en tamaño (un tamaño considerable al incluir el paquete de integración con Spark), lo cual hacía que el árbol de dependencia fuera bien extenso y además afectaba la portabilidad y usabilidad de JCLAL en aquellos usuarios que solamente querían usar las características básicas del framework.

En la nueva versión se optó por un diseño modular inspirado en el diseño de Apache Spark y Spring [10], separando las características del framework en los distintos módulos que componen el sistema. De esta manera, el proyecto fue



dividido en 3 módulos: **jclal-core** que tiene las funcionalidades básicas de JCLAL, el módulo **jclal-gui** que incluye la nueva interfaz visual y **jclal-spark** que comprende el procesamiento distribuido con Spark.

La modularidad de JCLAL se gestionó mediante Apache Maven [11], el cual es una herramienta popular para la gestión de proyectos software, que facilita la administración de dependencias y un amplio conjunto de estándares para el proceso de desarrollo del software. Si el usuario decide emplear Maven como administrador de dependencias, el *groupid* para JCLAL sería **net.sf.jclal**. El siguiente ejemplo muestra cómo instalar el núcleo de JCLAL (**jclal-core**) en una aplicación; de esta manera Maven gestiona las dependencias necesarias para usar solamente el módulo **jclal-core**.

```
<dependencies>
  <dependency>
    <groupId>net.sf.jclal</groupId>
    <artifactId>jclal-core</artifactId>
    <version>2.0</version>
  </dependency>
</dependencies>
```

### III. ENTORNO VISUAL PARA JCLAL

Es común que los framework de aprendizaje automático dispongan de una interfaz gráfica de usuario (GUI, por sus siglas en inglés) para facilitar la configuración, ejecución y análisis de resultados de los experimentos, reduciendo así el tiempo y trabajo necesario de los investigadores. Tal es el caso de Weka, VisualJCLEL [12], Eva2 [13], OTA [14] y HeuristicLab [15] que permiten a los investigadores sin un amplio conocimiento de su funcionamiento interno, o incluso sin habilidades de programación, utilizar estos framework de forma intuitiva.

VisualJCLAL es un módulo GUI que permite trabajar con el framework de forma intuitiva y flexible, acercando JCLAL a los usuarios no expertos en el dominio. Este entorno visual está inspirado en la arquitectura de Weka y VisualJCLEC. VisualJCLAL permite aprovechar la mayoría de las funcionalidades que brinda su framework base, y hasta el momento brinda la opción de utilizar estrategias de AL diseñadas para crear modelos predictivos sobre datos clasificados con una sola etiqueta (*single-label learning*) y datos clasificados con múltiples etiquetas (*multi-label learning*) [2].

VisualJCLAL brinda también la posibilidad de incluir escenarios de AL, algoritmos y estrategias de consulta mediante *plugins* creados por el usuario, gracias al uso de una arquitectura basada en componentes y al diseño flexible de clases e interfaces de JCLAL. Para ello el usuario utilizará la opción de agregar un nuevo *plugin* al sistema donde sus clases serán añadidas a los archivos de configuración en formato **.props** y serán mostrados en la GUI aquellos componentes que implementen la interfaz *IPlugin*. Estos parámetros se incluirán automáticamente dentro de las opciones de la interfaz gráfica usando la estructura modular y el generador de interfaces del entorno de usuario.

Por otra parte, este módulo aprovecha las posibilidades de JCLAL en su versión 2.0 para la ejecución de los algoritmos en forma paralela y distribuida (esta última utilizando el

framework Apache Spark), además de otras funcionalidades que resultan muy útiles para la realización de experimentos de AL.

La Figura 1 muestra la pantalla inicial que aparece tras ejecutar VisualJCLAL. A partir de ella se tienen tres opciones principales:

- Crear nuevo experimento (*New Experiment*): permite crear una nueva configuración desde cero para la ejecución de un experimento.
- Cargar la configuración de un experimento (*Make from XML*): permite cargar una configuración de un experimento creado anteriormente y que se encuentra almacenado en un archivo XML.
- Ver resultados (*View results*): permite analizar de forma gráfica los resultados de los experimentos ejecutados en JCLAL.



Figura 1. Interfaz inicial.

A la interfaz de configuración de un experimento se puede acceder a través de la opción *New Experiment* o cargando una configuración existente mediante la opción *Make from XML*. Como se puede observar en la Figura 2, en las diferentes pestañas de la interfaz se pueden configurar todos los parámetros necesarios para la ejecución del experimento.

En cuanto a la opción *View results*, esta nos permite cargar los ficheros generados por JCLAL y analizar gráficamente los resultados de un experimento, como se muestra en la Figura 3. Mediante la selección de una medida de evaluación se puede observar el comportamiento de varias curvas de aprendizaje al mismo tiempo, permitiendo realizar una comparación visual entre diferentes estrategias de AL. Además, esta interfaz permite configurar y analizar las gráficas mediante el cambio de colores, ocultar o mostrar curvas, definir rangos de evaluación, cambiar las formas de las líneas y calcular el área bajo una curva de aprendizaje.

Otra opción importante que brinda VisualJCLAL es la posibilidad de crear un estudio experimental con múltiples configuraciones a partir de una configuración básica (la configuración base debe contar con los parámetros mínimos

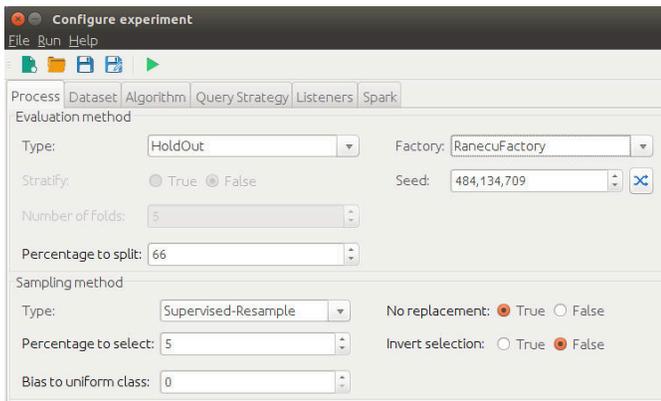


Figura 2. Interfaz para la configuración de un experimento.

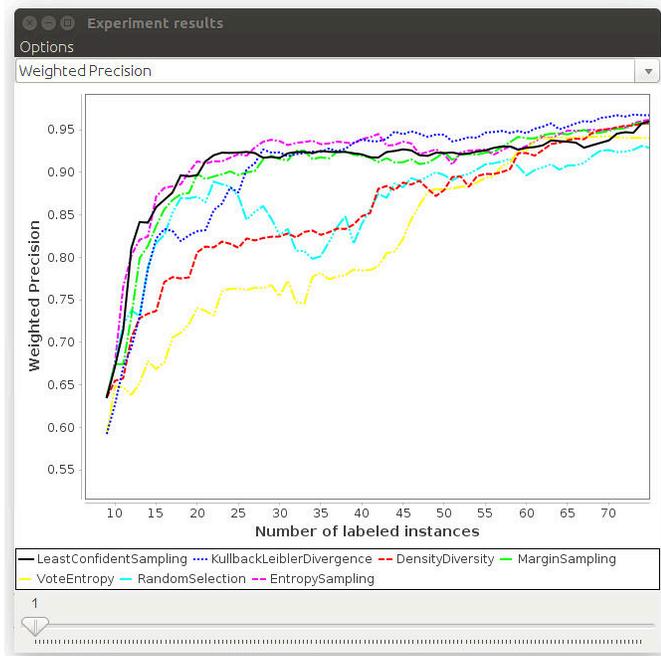


Figura 3. Interfaz de usuario para la visualización de resultados.

necesarios para la ejecución de un experimento). En la Figura 4 se puede observar cómo se pueden generar  $N$  configuraciones en dependencia de las opciones escogidas.

Por último, se cuenta con la opción de chequear cómo quedaría la configuración del experimento antes de ser almacenada en un fichero, como se muestra en la Figura 5.

#### IV. INTEGRACIÓN DE JCLAL CON EL FRAMEWORK SPARK

*Big Data* es un término muy popular en la actualidad, que hace referencia a problemas que involucran volúmenes de datos que superan la capacidad de los software clásicos y las máquinas convencionales para ser capturados, gestionados y procesados en un tiempo razonable. Apache Spark es uno de los framework más populares para el procesamiento de enormes conjuntos de datos, el cual implementa el paradigma de

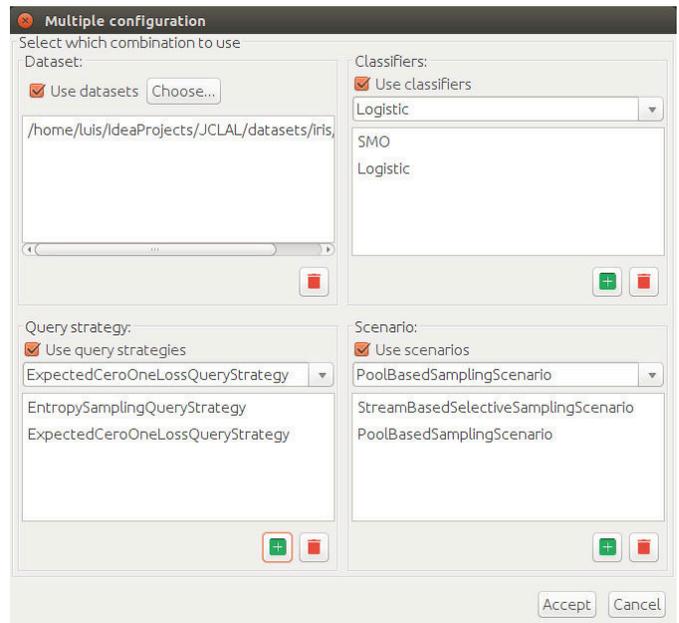


Figura 4. Creación de un estudio experimental.



Figura 5. Vista previa del archivo de configuración.

programación MapReduce [16] propuesto por Google. Spark almacena los resultados intermedios en memoria, logrando ejecutar aplicaciones mucho más rápido que las soluciones desarrolladas con Hadoop [17], lo cual hace de Spark una solución más adecuada para el desarrollo de algoritmos de aprendizaje automático altamente escalables. En este sentido, Spark cuenta con la librería MLlib [18] para el desarrollo de algoritmos distribuidos, la cual tiene implementaciones distribuidas de algunos de los algoritmos supervisados y no supervisados más populares, como Naive Bayes [19], árboles de decisión [20] y *k-means* [21].

La versión 1.0 de JCLAL se encontraba limitada a la hora de ejecutar experimentos con grandes conjuntos de datos, principalmente porque los algoritmos de aprendizaje que provee el framework Weka, o Mulan [22] para el caso de datos multi-etiqueta, no están diseñados para trabajar en este tipo de escenarios. En la versión actual de JCLAL se ha desarrollado



un módulo que integra a JCLAL con Spark, aprovechando las ventajas que tiene este último para el procesamiento paralelo y distribuido de datos masivos. El módulo de AL distribuido (**jclal-spark**) está diseñado de forma tal que puede trabajar con los modelos de clasificación que provee la librería MLlib. La arquitectura es similar a la de **jclal-core**, siendo la estructura de paquetes **net.sf.jclal.spark.\***.

Para utilizar **jclal-spark** a través de Maven hay que añadir el *artifactid* de este módulo, de esta manera se instalan automáticamente todas las dependencias necesarias para el trabajo con Spark. Además, en el fichero de configuración de un experimento, se debe incluir la etiqueta que indica la configuración para conectarse al servidor Spark. La etiqueta **master** especifica la dirección donde se encuentra el nodo maestro y en **app-name** se indica el nombre que se desea asignar al trabajo.

```
<spark>
  <master>spark://localhost:7077</master>
  <app-name>MyAlJob</app-name>
</spark>
```

Debido a que Spark provee sus propios modelos de clasificación, **jclal-spark** implementa las clases *SparkClassifier* y *SparkCommitteeClassifier* que sirven de interfaz para acceder a dichos clasificadores directamente (ver Figura 6). La clase encargada de realizar las evaluaciones de los clasificadores de Spark es *SparkSingleLabelEvaluation*, que además provee las medidas de tiempo de ejecución e información acerca de los conjuntos de datos.

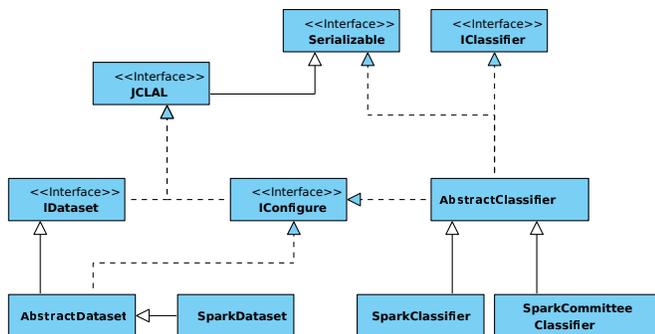


Figura 6. Diagrama de las clases principales del paquete **jclal-spark**.

Es válido destacar que el procesamiento de los conjuntos de datos en un ambiente distribuido es completamente diferente a como se hace en **jclal-core**. La clase *SparkDataset* se ha implementado para el manejo de datos distribuidos a través del conjunto de acciones y operadores que brinda la librería Spark. Los datos pueden ser cargados directamente desde disco o en un sistema de archivos distribuidos los cuales son primeramente indexados para luego ser procesados en el framework. En la nueva versión de JCLAL se añadió la etiqueta **format** para especificar el formato del conjunto de datos, logrando una mayor compatibilidad con Spark y otras librerías que se puedan incluir en el futuro. El ejemplo siguiente muestra como utilizar un conjunto de datos en formato **libsvm** empleando *SparkDataset*.

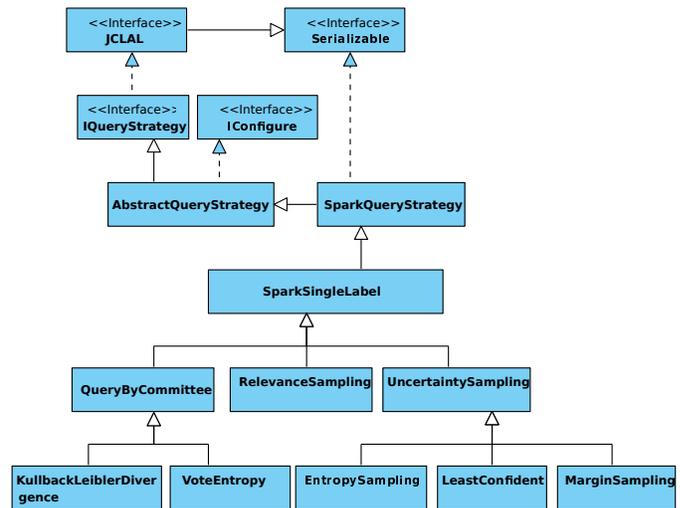


Figura 7. Diagrama de clases de las estrategias de consulta implementadas en el módulo **jclal-spark**.

```
<file-dataset type="net.sf.jclal.spark.dataset.SparkDataset">
  <path>path/to/dataset</path>
  <format>libsvm</format>
</file-dataset>
```

Respecto a las estrategias de consultas de AL implementadas en el paquete **jclal-spark**, hasta el momento están implementadas aquellas estrategias de consultas que se adaptan directamente al paradigma MapReduce, pero se espera implementar próximamente el resto de estrategias contenidas en **jclal-core**. La figura 7 muestra el diagrama de clases de las estrategias de consulta que actualmente soporta el módulo **jclal-spark**; estas son *Relevance Sampling*, y todas aquellas derivadas de *Uncertainty Sampling* (*Entropy Sampling*, *Least Confident* y *Margin Sampling*) y *Query By Committee* (*Kullback Leibler Divergence* y *Vote Entropy*).

Por último, en **jclal-spark** están implementados los métodos de evaluación clásicos: *Hold-Out*, *k-Fold Cross Validation*, *5X2 Cross Validation* y *Leave One Out Cross Validation*. En el caso de los métodos de validación cruzada se utilizaron funciones de Spark que están optimizadas para la creación de los *folds* en conjuntos de datos distribuidos.

## V. CONCLUSIONES

En este trabajo se describieron las mejoras y nuevas funcionalidades que se incluyen en la nueva versión del framework JCLAL. En su nueva versión, el núcleo de JCLAL cuenta con una nueva estructura de clases y funcionalidades que lo convierten en un framework más potente para la investigación en el área de AL. Se logró una mayor flexibilidad e independencia en la manipulación de los conjuntos de datos, haciendo posible integrar a JCLAL con datos provenientes de cualquier otro framework. Además, se le dio un mayor soporte a algoritmos de aprendizaje incremental, lo cual posibilita una mayor eficiencia en el proceso de construcción de modelos predictivos. Por otra parte, se añadió un paquete que permite realizar contrastes de hipótesis mediante test estadísticos no

paramétricos. Otra nueva mejora radica en la descomposición del framework en módulos independientes, lo cual facilita su portabilidad y distribución. De esta manera se puede trabajar con las funciones deseadas del framework sin tener instaladas todas y cada una de las librerías del árbol de dependencias.

JCLAL 2.0 también incorpora el entorno VisualJCLAL que permite trabajar con el framework de forma intuitiva y flexible, acercando JCLAL a los usuarios no expertos en el dominio y permitiendo un ahorro significativo de tiempo. Por último, se incorporó un nuevo e importante módulo, que permite de forma sencilla aplicar programación distribuida en JCLAL. El módulo de AL distribuido utiliza la popular librería Spark, lo cual permite el uso de JCLAL 2.0 en problemas *Big Data* y posibilita una mejor acogida por parte de la comunidad científica.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto TIN2017-83445-P del Ministerio de Economía y Competitividad y Fondos FEDER. También ha sido financiado por el contrato i-PFIS no. IFI17/00015 otorgado por el Instituto de Salud Carlos III.

#### REFERENCIAS

- [1] O. Reyes, A. H. Altalhi, and S. Ventura, "Statistical comparisons of active learning strategies over multiple datasets," *Knowledge-Based Systems*, vol. 145, pp. 274–288, 2018.
- [2] O. Reyes, C. Morell, and S. Ventura, "Effective active learning strategy for multi-label learning," *Neurocomputing*, vol. 273, pp. 494–508, 2018.
- [3] O. Reyes and S. Ventura, "Evolutionary strategy to perform batch-mode active learning on multi-label data," *ACM Trans. Intell. Syst. Technol.*, vol. 9, no. 4, pp. 46:1–46:26, 2018.
- [4] Y. Y. Yang, S. C. Lee, Y. A. Chung, T. E. Wu, S. A. Chen, and H. T. Lin, "libact: Pool-based active learning in python," *arXiv preprint arXiv:1710.00379*, 2017.
- [5] O. Reyes, E. Pérez, M. C. Rodríguez-Hernández, H. M. Fardoun, and S. Ventura, "JCLAL: a java framework for active learning," *The Journal of Machine Learning Research*, vol. 17, no. 1, pp. 3271–3275, 2016.
- [6] M. Zaharia, M. Chowdhury, M. J. Franklin, S. Shenker, and I. Stoica, "Spark: Cluster computing with working sets," in *Proceedings of the 2Nd USENIX Conference on Hot Topics in Cloud Computing*, ser. HotCloud'10. Berkeley, CA, USA: USENIX Association, 2010, pp. 10–10.
- [7] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten, "The WEKA data mining software: an update," *ACM SIGKDD explorations newsletter*, vol. 11, no. 1, pp. 10–18, 2009.
- [8] A. Bifet, G. Holmes, R. Kirkby, and B. Pfahringer, "MOA: massive online analysis," *Journal of Machine Learning Research*, vol. 11, pp. 1601–1604, 2010.
- [9] J. Alcalá-Fdez, L. Sanchez, S. Garcia, M. J. del Jesus, S. Ventura, J. M. Garrell, J. Otero, C. Romero, J. Bacardit, V. M. Rivas *et al.*, "Keel: a software tool to assess evolutionary algorithms for data mining problems," *Soft Computing*, vol. 13, no. 3, pp. 307–318, 2009.
- [10] R. Johnson, *Expert One-on-one J2EE Design and Development*. Wrox Press, 2002.
- [11] F. P. Miller, A. F. Vandome, and J. McBrewster, "Apache maven," 2010.
- [12] J. I. Jaen, J. R. Romero, and S. Ventura, "VisualJCLEC: A visual framework for evolutionary computation," in *Intelligent Systems Design and Applications (ISDA), 2012 12th International Conference on*. IEEE, 2012, pp. 119–125.
- [13] M. Kronfeld, H. Planatscher, and A. Zell, "The EvA2 optimization framework," in *International Conference on Learning and Intelligent Optimization*. Springer, 2010, pp. 247–250.
- [14] J. Brownlee *et al.*, "Oat: The optimization algorithm toolkit," *Centre for Information Technology Research (CITR), Swinburne University of Technology, Victoria, Australia, Technical Report A*, vol. 20071220, 2007.
- [15] S. Wagner and M. Affenzeller, "Heuristicslab: A generic and extensible optimization environment," in *Adaptive and Natural Computing Algorithms*. Springer, 2005, pp. 538–541.
- [16] J. Dean and S. Ghemawat, "MapReduce: simplified data processing on large clusters," *Communications of the ACM*, vol. 51, no. 1, pp. 107–113, 2008.
- [17] M. Zaharia, M. Chowdhury, T. Das, A. Dave, J. Ma, M. Mccauley, M. Franklin, S. Shenker, and I. Stoica, "Fast and interactive analytics over hadoop data with spark," *Usenix Login*, vol. 37, no. 4, pp. 45–51, 2012.
- [18] X. Meng, J. Bradley, B. Yavuz, E. Sparks, S. Venkataraman, D. Liu, J. Freeman, D. Tsai, M. Amde, S. Owen *et al.*, "Mllib: Machine learning in apache spark," *The Journal of Machine Learning Research*, vol. 17, no. 1, pp. 1235–1241, 2016.
- [19] N. Friedman, D. Geiger, and M. Goldszmidt, "Bayesian network classifiers," *Machine learning*, vol. 29, no. 2-3, pp. 131–163, 1997.
- [20] J. R. Quinlan, *C4.5: Programs for Machine Learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1993.
- [21] S. Lloyd, "Least squares quantization in PCM," *IEEE transactions on information theory*, vol. 28, no. 2, pp. 129–137, 1982.
- [22] G. Tsoumakas, E. Spyromitros-Xioufis, J. Vilcek, and I. Vlahavas, "Mulan: A java library for multi-label learning," *Journal of Machine Learning Research*, vol. 12, pp. 2411–2414, 2011.



# Resolviendo el problema de regresión multi-salida mediante *Gene Expression Programming*

Oscar Reyes

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Email: ogreyes@uco.es

Jose M. Moyano

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Email: jmoyano@uco.es

Jose M. Luna

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Email: jmluna@uco.es

Sebastián Ventura

Dpto. Informática y Análisis Numérico  
Universidad de Córdoba  
Email: sventura@uco.es

**Resumen**—En los últimos años, el estudio de problemas donde los ejemplos están asociados a múltiples variables objetivo al mismo tiempo ha ganado un creciente interés en la comunidad científica. En este trabajo se propone un método basado en *Gene Expression Programming* para darle solución al problema de regresión multi-salida. El método propuesto se enfoca en la regresión simbólica, lo cual permite crear un modelo predictivo multi-salida sin tener conocimiento previo de las relaciones existentes en los datos. La codificación de un individuo de la población se realiza mediante un cromosoma de varios genes, donde cada gen codifica una expresión matemática que produce la salida para una variable objetivo, y así cada individuo de la población representa directamente una posible solución al problema. Los operadores usados en el proceso evolutivo permiten la constante creación de nuevo material genético, y algunos de ellos favorecen la detección de las dependencias existentes entre variables objetivo. El estudio experimental realizado en 8 conjuntos de datos muestra los beneficios y efectividad del método propuesto para resolver el problema de regresión multi-salida.

## I. INTRODUCCIÓN

En la última década, el estudio de problemas donde cada ejemplo del conjunto de datos está asociado a múltiples variables objetivo (variables de salida) ha tenido un creciente interés en la comunidad de aprendizaje automático, debido principalmente al elevado número de aplicaciones reales que pueden ser modeladas dentro de este paradigma. El objeto de estudio de la regresión multi-salida o *multi-target regression* (MTR), se enfoca en la predicción simultánea de múltiples variables objetivo continuas usando un único conjunto de variables descriptoras (variables de entrada) [1, 2]. MTR está presente en varios dominios de aplicación, tales como en el modelado ecológico [3], procesado de señales [4], y la eficiencia energética [5].

A día de hoy, se han propuesto un número considerable de métodos para resolver el problema MTR, los cuales se pueden categorizar en dos grupos: métodos de transformación de problemas y métodos de adaptación de algoritmos [1]. Los métodos de transformación descomponen un problema de regresión multi-salida en varios problemas de regresión simple (es decir, con una sola variable objetivo), y por último mediante un proceso de agregación se obtienen las prediccio-

nes finales. En este sentido, la mayoría de los métodos de transformación para MTR han sido inspirados en aproximaciones existentes para el aprendizaje multi-etiqueta [2, 6]; en este último paradigma cada ejemplo está asociado a múltiples variables objetivo binarias. Por otro lado, la categoría de adaptación de algoritmos incluye aquellos métodos que no descomponen el problema MTR en problemas de regresión simple, sino que tratan directamente los datos multi-salida. Dentro de esta categoría se han propuesto un amplio número de métodos, tales como métodos estadísticos [7], árboles de regresión [3], algoritmos basados en reglas [8], máquinas de vectores soporte [9] y métodos locales [10].

Entre los paradigmas existentes más populares para resolver problemas de regresión se encuentra la regresión simbólica, donde el objetivo es buscar una expresión matemática que se ajuste a un conjunto de datos dado. En este tipo de técnica no se proporciona ningún modelo en particular como punto de partida, sino que las expresiones se forman por medio de la codificación de bloques matemáticos, lo cual provee de una selección de características implícita en el proceso de construcción de expresiones, y además puede beneficiar la detección de relaciones complejas en los datos. Las técnicas de regresión simbólica han sido aplicadas a un gran número de problemas reales [11], destacando el uso de algoritmos evolutivos para su resolución [12]. Entre las técnicas de computación evolutiva más adecuadas para el desarrollo de métodos de regresión simbólica se encuentra *Gene Expression Programming* (GEP) [12–14], una aproximación que se sitúa entre los algoritmos genéticos y la programación genética, aprovechando así las ventajas de ambas técnicas. [13]. GEP emplea una población de individuos, selecciona padres de acuerdo a su *fitness* y evoluciona la población utilizando operadores genéticos, tal y como hacen los algoritmos genéticos y la programación genética. Sin embargo, la principal diferencia radica en la forma en que los individuos son codificados. En este caso, los individuos se codifican como cadenas lineales de longitud fija (como en algoritmos genéticos), que luego se expresan como árboles de diferentes tamaños y formas (como en programación genética) [13].

Hasta el momento, los trabajos existentes que aplican GEP para regresión simbólica se han restringido a solucionar problemas de regresión simple. Es de destacar que al tratar de solucionar el problema MTR mediante regresión simbólica usando la técnica GEP aparecen dificultades adicionales que no existían en el contexto de la regresión simple, como es la dependencia estadística que puede existir entre las variables objetivo. En este sentido, varios estudios recientes han demostrado que es vital detectar y explotar correctamente dichas dependencias de cara a mejorar el rendimiento predictivo de los algoritmos de regresión [2, 9, 10, 15].

En este trabajo, se propone un método basado en GEP que resuelve el problema MTR mediante regresión simbólica. El método diseñado no divide el problema multi-salida en varias tareas de salida simple, sino que trata directamente con los datos multi-salida, por lo que se obtiene un método con un coste computacional aceptable en conjuntos de datos con un elevado número de variables objetivo. Los individuos se representan mediante un cromosoma con codificación multi-génica, donde cada gen representa una función matemática que predice el valor de una variable objetivo; de esta manera cada individuo representa una solución completa al problema MTR. El poder creativo de GEP permite la constante creación de nuevo material genético, permitiendo una mejor exploración del espacio de búsqueda. Además, el método puede detectar las dependencias existentes entre variables objetivo por medio de los operadores de transposición o recombinación de genes entre cromosomas.

La contribución principal de este trabajo es la introducción de un método basado en GEP para el problema MTR. Este trabajo representa un estudio inicial, donde se pretende analizar los beneficios del paradigma GEP para construir modelos de regresión multi-salida. La efectividad del método desarrollado se comprobó mediante un estudio experimental en 8 conjuntos de datos, demostrando que se obtienen resultados prometedores mediante la comparación contra otros dos métodos del estado del arte.

El resto de este trabajo se organiza de la siguiente manera: en la Sección II se describen los fundamentos del método propuesto; la configuración del estudio experimental, así como la discusión de los resultados son presentados en la Sección III; finalmente, en la Sección IV se presentan las conclusiones del presente trabajo.

## II. MÉTODO BASADO EN GEP

En esta sección se describe el método propuesto basado en GEP para resolver el problema MTR mediante regresión simbólica. Antes de describir el método en sí, se definen algunas notaciones que son utilizadas a lo largo del trabajo.

Sea  $S = \{(\mathbf{x}^1, \mathbf{y}^1), (\mathbf{x}^2, \mathbf{y}^2), \dots, (\mathbf{x}^n, \mathbf{y}^n)\}$  un conjunto de datos de  $n$  ejemplos de entrenamiento. Una instancia  $i \in S$  se representa como una tupla  $(\mathbf{x}^i, \mathbf{y}^i)$ , donde  $\mathbf{x}^i \in \mathcal{X}$  e  $\mathbf{y}^i \in \mathcal{Y}$  son los vectores de entrada y salida de  $i$ , respectivamente.  $\mathcal{X}$  representa el espacio de entrada que contiene  $d$  variables descriptivas  $x_1, x_2, \dots, x_d$ , mientras que  $\mathcal{Y}$  representa el espacio de salida, que contiene  $q$  variables objetivo  $y_1, y_2, \dots, y_q$ .

Por otro lado,  $x_\ell^i$  denota el valor de la  $\ell$ -ésima variable descriptiva para el ejemplo  $i$ , mientras que  $y_\ell^i$  representa el valor de su  $\ell$ -ésima variable objetivo. En el problema MTR el objetivo principal es construir una función  $f : \mathcal{X} \rightarrow \mathcal{Y}$  que prediga un vector de variables objetivo  $\hat{\mathbf{y}}$  a partir de un vector de variables descriptivas nunca antes visto  $\mathbf{x}$ . Por otro lado, como se hace uso de regresión simbólica, es necesaria la definición del conjunto de símbolos no terminales (funciones)  $F = \{-, +, /, *, \dots\}$  y el conjunto de símbolos terminales  $T = \{x_1, x_2, \dots, x_d\}$ , donde cada símbolo terminal representa una variable descriptiva  $x_\ell \in \mathcal{X}$ .

En el paradigma GEP, un gen está compuesto por una cabeza y una cola. La cabeza puede contener símbolos que pertenezcan tanto a los conjuntos  $F$  como  $T$ , mientras que la cola puede contener solo símbolos terminales. La longitud de la cabeza ( $h$ ) se escoge de acuerdo al problema, mientras que la longitud de la cola ( $t$ ) se calcula como  $t = h(a - 1) + 1$ , donde  $a$  es el número de argumentos de la función con máxima aridad en  $F$ . Tenga en cuenta que a mayor  $h$ , más larga y compleja será la expresión matemática que se podrá codificar, sin embargo hay que considerar que también será mayor el espacio de búsqueda. Una desventaja de la mayoría de métodos basados en GEP reside en la continua transformación de los cromosomas en árboles de expresión (ETs, por sus siglas en inglés) y su correspondiente evaluación para obtener el *fitness* de los individuos. Para evitar esto, en este trabajo los genes se codifican mediante notación prefija, siguiendo el enfoque propuesto por Peng et al. en [12], permitiendo la evaluación de los individuos sin construir los ETs, y mejorando por tanto significativamente la eficiencia computacional de GEP. La Figura 1 representa un gen de un cromosoma, que en este caso contiene la notación prefija de la ecuación matemática

$$f(\mathbf{x}) = \sqrt{\left(\frac{x_1}{x_4 * x_5} - \sqrt{x_1}\right)} + x_1.$$

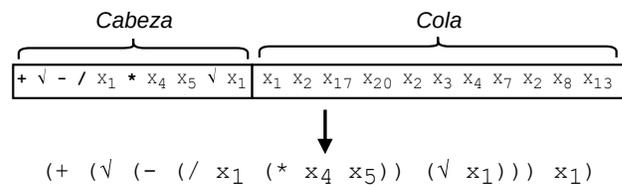


Figura 1. Un gen con  $h = 10$  y su correspondiente fenotipo representado en notación prefija.

Se define una población de  $p$  individuos, donde cada individuo representa una posible solución completa al problema MTR. Para ello, un individuo es representado mediante un cromosoma multi-génico, compuesto por  $q$  genes de igual longitud  $c = [g_1, g_1, \dots, g_q]$ , conteniendo un gen por cada variable objetivo del problema. Por tanto, el gen  $\ell$ -ésimo de un cromosoma codifica una función matemática que se puede utilizar posteriormente como modelo predictivo para estimar el valor de la variable objetivo  $y_\ell^i$  de un ejemplo de prueba  $i$ .

Para calcular el nivel de adaptación de un individuo se calcula el error cuadrático medio relativo (*average relative*



root mean square error, aRRMSE) en promedio para todas las variables objetivo sobre el conjunto de entrenamiento  $S$ ,

$$\frac{1}{q} \sum_{\ell=1}^q \sqrt{\frac{\sum_{i \in S} (y_{\ell}^i - \hat{y}_{\ell}^i)^2}{\sum_{i \in S} (y_{\ell}^i - \bar{y}_{\ell})^2}}, \quad (1)$$

donde  $y_{\ell}^i$  e  $\hat{y}_{\ell}^i$  son los valores de la  $\ell$ -ésima variable objetivo en los vectores de salida conocido ( $\mathbf{y}^i$ ) y predicho ( $\hat{\mathbf{y}}^i$ ) para el ejemplo  $i$ , respectivamente. Por otro lado,  $\bar{y}_{\ell}$  es el valor medio de la variable objetivo  $\ell$ -ésima en el conjunto de entrenamiento  $S$ . Resumiendo, dado un individuo de la población, la función de *fitness* mide el error cuadrático medio relativo (RRMSE) para la primera variable objetivo, evaluando la función matemática codificada en el primer gen del cromosoma en cada ejemplo de entrenamiento  $i \in S$ , y así este proceso se realiza para todas las variables objetivo obteniendo finalmente el valor promedio entre todas ellas.

La población inicial se crea de manera aleatoria, pero siempre controlando la diversidad entre los individuos generados. Un cromosoma se forma creando cada uno de sus genes de la siguiente manera: (I) los símbolos en la cabeza del gen se seleccionan aleatoriamente de  $F \cup T$ , asegurando que el primer elemento (raíz) de la cabeza sea un símbolo no terminal; y (II) los símbolos de la cola se seleccionan aleatoriamente del conjunto  $T$ . Un individuo se añade a la población inicial si tiene una similitud respecto al resto de la población menor que un umbral específico. La similitud entre dos individuos se calcula como

$$s(c^i, c^j) = 1 - \frac{\sum_{\ell=1}^q h(c_{\ell}^i, c_{\ell}^j)}{q^2(t+h)}, \quad (2)$$

donde  $c^i$  y  $c^j$  son los cromosomas de los individuos  $i$  y  $j$ , respectivamente. La función  $h(c_{\ell}^i, c_{\ell}^j)$  mide el número de símbolos distintos, sumados a lo largo de las  $t+h$  posiciones, en el  $\ell$ -ésimo gen de los cromosomas  $c^i$  y  $c^j$ . Este método permite la creación de una población inicial con suficiente diversidad, lo cual evita la convergencia temprana del método a un mínimo local.

Respecto al operador de selección, se ha utilizado una selección por torneo binario para crear la población intermedia de padres. Se empleó una baja presión selectiva para que no solo se favorezca a los mejores individuos en el proceso de selección, sino que se estimule también la diversidad entre los individuos seleccionados.

En cuanto al operador de mutación, los padres mutan con una tasa de mutación  $p_m$  y se ha diseñado un operador que siempre genera individuos válidos. Se han empleado varios puntos de mutación por cromosoma ( $n_{mp}$ ), y dicho operador realiza los siguientes pasos para cada uno de los puntos de mutación: (I) se selecciona aleatoriamente uno de los genes del individuo; (II) se selecciona aleatoriamente una posición dentro del gen; (III) si la posición pertenece a la cabeza, el símbolo en dicha posición se cambia aleatoriamente por un símbolo que pertenece a  $F \cup T$ , excepto en el caso de que la posición seleccionada sea la raíz, donde se reemplazará

necesariamente por un símbolo en  $F$ ; (IV) si la posición pertenece a la cola, el símbolo en la posición seleccionada se cambia por otro símbolo en  $T$ .

Una característica de GEP que lo diferencia de otros paradigmas evolutivos es que fragmentos del genoma se pueden activar y saltar a otro lugar en el cromosoma (elementos transponibles), y esta característica da lugar a la definición de los siguientes operadores de transposición: *insertion sequence* (IS), *root insertion sequence* (RIS) y *gene transposition* (GT). El operador IS se utiliza con una pequeña probabilidad  $p_{is}$ , y permite que pequeños fragmentos de un gen (fragmentos con una función o un terminal en la primera posición) se transpongan a la cabeza de los genes, excepto a la raíz; este operador se ejecuta  $n_{is}$  veces sobre un cromosoma. El operador IS realiza los siguientes pasos: (I) dado un cromosoma, se selecciona un gen a partir del cual un fragmento de longitud entre  $[1, l_{is}]$  ( $l_{is}$ -máxima longitud de un fragmento) se selecciona aleatoriamente; y (II) se selecciona un gen de destino donde insertar el fragmento copiado empezando en una posición aleatoria de la cabeza del gen (distinta de la raíz).

Por otra parte, el operador RIS se usa con una probabilidad baja  $p_{ris}$ , y permite que fragmentos pequeños con un símbolo no terminal en la primera posición se transpongan a la raíz de los genes; este operador se realiza  $n_{ris}$  veces sobre un cromosoma. Para ello, este operador realiza los siguientes pasos: (I) dado un cromosoma, se selecciona aleatoriamente un gen; (II) se selecciona un punto aleatorio en la cabeza del gen seleccionado y se busca hacia atrás hasta encontrar un símbolo no terminal; (III) y este fragmento se copia empezando en la raíz del gen. Durante la transposición RIS, los símbolos en la cabeza se desplazan hacia la derecha hasta acomodar completamente el nuevo fragmento copiado. Al igual que en el operador de transposición IS, la cola del gen que se transpone y los genes adyacentes no se modifican.

Por último, el operador GT se usa con una pequeña probabilidad  $p_{gt}$ , y permite que genes completos se transpongan al principio de los cromosomas. Para ellos, este operador realiza los siguientes pasos: (I) dado un cromosoma, se selecciona aleatoriamente un gen y se elimina de su lugar de origen; (II) y el gen se copia al principio del cromosoma, mientras que los genes restantes se desplazan a la derecha, manteniéndose la longitud original del cromosoma. Los operadores IS, RIS y GT producen siempre individuos válidos, sin embargo, hay que tener en cuenta que dichos operadores pueden modificar drásticamente la expresión de un gen; cuanto más cercano a la raíz del gen ocurra la transposición, más profundo será el cambio en la expresión del gen [13].

En el método propuesto también se aplicaron tres tipos de recombinación o cruce: recombinación en un punto (OP), recombinación en dos puntos (TP), y recombinación de genes (GP), con probabilidades de aplicación  $p_{op}$ ,  $p_{tp}$ , y  $p_{gp}$ , respectivamente. Dados dos cromosomas, el operador OP realiza el cruce sobre un punto seleccionado aleatoriamente. El operador TP seleccionan aleatoriamente dos puntos y los fragmentos entre dichos puntos se intercambian entre ambos padres. En GP se intercambian los genes, ubicados en una

posición seleccionada aleatoriamente, entre ambos padres. Es de destacar que en los tres operadores, se cruzan dos padres y se obtienen dos nuevos individuos válidos. Además, el operador TP tiene más poder de transformación que el OP en problemas más complejos, especialmente cuando se utilizan cromosomas multigénicos. Por último, el operador GP no crea genes nuevos como OP y TP, sin embargo, cabe destacar que este operador puede introducir nuevo material en la población, ya que los genes intercambiados entre padres pueden ser muy diferentes.

Finalmente, se ha seguido un esquema generacional para actualizar la población que pasa de una generación a otra, donde el peor individuo de la nueva población es reemplazado por el mejor individuo de la población anterior. El método propuesto (GPMTR, de ahora en adelante) sigue los pasos que se muestran en la Figura 2. Estos pasos se realizan  $n_g$  veces (número de generaciones), y al final del proceso se selecciona el mejor individuo encontrado a lo largo de todas las generaciones, cuyo cromosoma representa un modelo de regresión multi-salida que puede ser utilizado posteriormente para predecir las variables objetivo de conjuntos de ejemplos nunca antes visto.

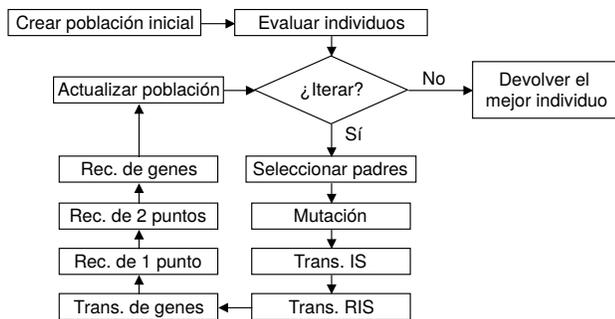


Figura 2. Diagrama de flujo del método GPMTR.

### III. ESTUDIO EXPERIMENTAL

En esta sección primero se explica la configuración de los experimentos realizados en este trabajo, y posteriormente se presenta un análisis y discusión de los resultados obtenidos.

#### III-A. Configuración de los Experimentos

Los experimentos se han ejecutado sobre ocho conjuntos de datos de regresión multi-salida<sup>1</sup>. La Tabla I muestra los conjuntos de datos utilizados y sus características, como el número de instancias ( $n$ ), variables descriptivas ( $d$ ) y variables objetivo ( $q$ ).

En el estudio experimental, se compara nuestra propuesta (GPMTR) con otros dos algoritmos del estado del arte para regresión multi-salida, *Single Target (ST)* y *Regressor Chains (RC)* [2]. Tanto ST como RC usan árboles de regresión como predictores de regresión simple, tal y como recomiendan sus autores. Los parámetros utilizados para la ejecución de

<sup>1</sup>Los conjuntos de datos están disponibles públicamente en <http://mulan.sourceforge.net/datasets-mtr.html>

Tabla I  
CONJUNTOS DE DATOS DE REGRESIÓN MULTI-SALIDA.

	$n$	$d$	$q$
slump	103	7	3
jura	359	15	3
sf1	323	10	3
atp1d	337	411	6
osales	639	413	12
wq	1060	16	14
oes97	334	263	16
oes10	403	298	16

GPMTR se muestran en la Tabla II; la mayoría de los valores son los recomendados por Ferreira [13]. Además, se utilizó una probabilidad global de cruce de 0.8, que corresponde con la suma de las probabilidades de los tres operadores de cruce utilizados.

Tabla II  
PARÁMETROS DEL ALGORITMO GPMTR.

Parámetro	Valor
Conjunto de funciones ( $F$ )	$\{-, +, /, *, \sqrt{\cdot}, \sin, \cos, \log\}$
Conjunto de terminales ( $T$ )	$\{x_1, x_2, \dots, x_d\}$
Tamaño de la población ( $p$ )	100
Número de puntos de mutación ( $n_{mp}$ )	2
Probabilidad de mutación ( $p_{mp}$ )	0,1
Número de fragmentos IS ( $n_{is}$ )	3
Máx. longitud de los fragmentos IS ( $l_{is}$ )	3
Probabilidad IS ( $p_{is}$ )	0,1
Número de fragmentos RIS ( $n_{ris}$ )	3
Probabilidad RIS ( $p_{ris}$ )	0,1
Probabilidad GT ( $p_{gt}$ )	0,1
Probabilidad OP ( $p_{op}$ )	0,2
Probabilidad TP ( $p_{tp}$ )	0,5
Probabilidad GP ( $p_{gp}$ )	0,1

Para la evaluación de los algoritmos, se utilizó la medida aRRMSE, que ha sido ampliamente usada para la evaluación de métodos de regresión multi-salida [1, 2]. La medida aRRMSE se calcula como se mostró en la Ecuación 1. En todos los experimentos, el valor de aRRMSE se estimó realizando un *10-folds cross-validation*, midiendo el error en cada uno de los conjuntos de test y promediando finalmente los resultados.

Para realizar comparaciones múltiples entre algoritmos, se ha utilizado el test de Friedman [16]. En casos donde el test de Friedman indicase que existen diferencias significativas en el rendimiento de los algoritmos, se ha realizado el test *post-hoc* de Holm [17] para realizar una comparación múltiple con un algoritmo de control. Por otra parte, en los casos donde se compararon dos métodos independientes, se empleó el test de Wilcoxon [18].

#### III-B. Resultados Experimentales

En el estudio experimental, primero se analizó el comportamiento de GPMTR considerando diferentes valores del parámetro  $h = \{5, 10, 15, 20\}$  y número de generaciones. La Tabla III muestra los resultados, donde en cada fila se han resaltado en negrita los mejores valores para cada  $h$ .

Se puede observar como en prácticamente todos los casos, cuando GPMTR se ejecutó con 500 generaciones, los individuos evolucionaron hacia un mejor modelo predictivo,



Tabla III  
RESULTADOS DE GEPMTR DEPENDIENDO DE  $h$  Y DEL NÚMERO DE GENERACIONES.

	$h = 5$		$h = 10$		$h = 15$		$h = 20$	
	100 g.	500 g.						
slump	<b>0,860</b>	0,872	0,848	<b>0,772</b>	0,864	<b>0,767</b>	0,845	<b>0,752</b>
jura	0,692	<b>0,669</b>	0,681	<b>0,646</b>	0,686	<b>0,644</b>	0,684	<b>0,642</b>
sf1	1,129	<b>1,083</b>	1,128	<b>1,128</b>	<b>1,142</b>	1,164	1,156	<b>1,141</b>
atp1d	0,555	<b>0,446</b>	0,541	<b>0,453</b>	0,545	<b>0,450</b>	0,544	<b>0,450</b>
osales	0,954	<b>0,860</b>	0,910	<b>0,861</b>	0,908	<b>0,881</b>	0,921	<b>0,888</b>
wq	0,976	<b>0,968</b>	0,974	<b>0,963</b>	0,975	<b>0,961</b>	0,976	<b>0,960</b>
oes97	0,660	<b>0,589</b>	0,650	<b>0,601</b>	0,658	<b>0,598</b>	0,666	<b>0,623</b>
oes10	0,530	<b>0,471</b>	0,530	<b>0,520</b>	0,546	<b>0,484</b>	0,541	<b>0,487</b>
<i>p-value</i>	<b>0,023</b>		<b>0,022</b>		<b>0,030</b>		<b>0,014</b>	

obteniendo un mejor rendimiento. Para cada valor diferente de  $h$ , se realizó el test de Wilcoxon para comparar el rendimiento de GEPMTR con 100 y 500 generaciones. Los *p-values* del test de Wilcoxon se muestran en la última fila de la Tabla III. El test estadístico rechazó la hipótesis nula en todos los casos para un nivel de significación  $\alpha=0,05$ , lo cual demuestra que el algoritmo con 500 generaciones obtiene resultados significativamente mejores que con 100 generaciones.

Una vez verificado que GEPMTR funciona mejor con un mayor número de generaciones, el estudio se centra en el valor de  $h$ . La Tabla IV muestra los *rankings* de GEPMTR ejecutado con diferentes valores de  $h$  y con 500 generaciones sobre cada conjunto de datos. Esta tabla es un resumen de la Tabla III, pero esta se centra en los valores de *ranking* en lugar de aRRMSE. En cada fila, el algoritmo con un mejor rendimiento obtiene un *ranking* de 1, el siguiente un *ranking* de 2, y así sucesivamente. La última fila muestra el valor de *ranking* medio devuelto por el test de Friedman.

Tabla IV  
VALORES DE RANKING CON DIFERENTES VALORES DE  $h$  Y 500 GENERACIONES.

	$h=5$	$h=10$	$h=15$	$h=20$
slump	4,00	3,00	2,00	<b>1,00</b>
jura	4,00	3,00	2,00	<b>1,00</b>
sf1	<b>1,00</b>	2,00	4,00	3,00
atp1d	<b>1,00</b>	4,00	2,50	2,50
osales	<b>1,00</b>	2,00	3,00	4,00
wq	4,00	3,00	2,00	<b>1,00</b>
oes97	<b>1,00</b>	3,00	2,00	4,00
oes10	<b>1,00</b>	4,00	2,00	3,00
<i>Ranking</i> medio	<b>2,13</b>	3,00	2,44	2,44

Se puede observar que, a pesar de que el test de Friedman no encontró diferencias significativas en el rendimiento de GEPMTR con los diferentes valores del parámetro  $h$ , la configuración con  $h=5$  fue la que mejor *ranking* medio obtuvo, mostrando una tendencia a que cuanto más simples sean los modelos, mejor es su rendimiento predictivo.

En la segunda fase del estudio experimental, se realizó una comparación entre GEPMTR y dos algoritmos del estado del arte en MTR. La Tabla V muestra los resultados; para esta comparación, los resultados que se muestran para GEPMTR son el mínimo de las diferentes configuraciones de  $h$  con 500 generaciones. La última fila de la tabla muestra los valores

de *ranking* medio obtenidos por el test de Friedman. En cada fila, el mejor valor de error se resalta en negrita. Los resultados muestran que el método propuesto obtiene mejores resultados que los otros dos algoritmos en siete de los ocho conjuntos de datos considerados, obteniendo también el mejor valor de *ranking* medio.

Tabla V  
COMPARACIÓN DE GEPMTR CON DOS ALGORITMOS DEL ESTADO DEL ARTE EN MTR.

	GEPMTR	ST	RC
slump	<b>0,752</b>	0,814	0,829
jura	<b>0,642</b>	0,696	0,704
sf1	1,083	1,127	<b>1,046</b>
atp1d	<b>0,446</b>	0,479	0,484
osales	<b>0,860</b>	0,925	0,965
wq	<b>0,960</b>	0,966	0,974
oes97	<b>0,589</b>	0,716	0,719
oes10	<b>0,471</b>	0,594	0,595
<i>Ranking</i> medio	<b>1,125</b>	2,125	2,750

El estadístico del test de Friedman fue igual a 10,75, y la hipótesis nula fue rechazada con un *p-value* de 0,005, existiendo diferencias significativas en el rendimiento de los algoritmos. Para detectar dónde estaban localizadas dichas diferencias se ejecutó el test de Holm, cuyos resultados se muestran en la Tabla VI, indicando que GEPMTR tiene un rendimiento predictivo significativamente mejor que el resto de algoritmos para un nivel de significación  $\alpha = 0,05$ .

Tabla VI  
P-VALUES AJUSTADOS CALCULADOS POR EL TEST DE HOLM.

	ST	RC
GEPMTR vs.	0,045	0,002

### III-C. Discusión

La representación multi-génica utilizada resultó ser una manera efectiva para representar los cromosomas, permitiendo que cada individuo constituya una solución diferente y completa para el problema MTR. La manera de crear la población inicial, así como el uso de un operador de selección con menor presión, permitió la evolución de una población con suficiente diversidad previniendo que el método quedase atrapado en un mínimo local o en valles aplanados en las primeras generaciones.

Operadores como el de transposición IS, y los de recombinación OP y TP pueden introducir material genético beneficioso. Así, buenos bloques existentes en genes más adaptados se pueden transferir a otros genes, favoreciendo el intercambio de información entre genes, y por tanto, el modelado de relaciones estadísticas entre variables objetivo.

En cuanto a la eficiencia computacional de GEPMTR, el hecho de haber usado notación prefija, y por tanto que los genes puedan ser evaluados sin construir su correspondiente árbol de expresión, hace que la evaluación de los individuos se haya acelerado significativamente. GEPMTR puede ser paralelizado fácilmente, y por tanto, se puede reducir significativamente su

tiempo de cómputo. Por otro lado, no se consume tiempo en la descomposición del problema MTR en varios problemas de regresión simple, sino que el método propuesto trata directamente con los datos multi-salida. Además, GEPMTR tiene implícito un proceso de selección de características que puede ser muy beneficioso en el proceso de aprendizaje de modelos de regresión; la expresión matemática codificada por un gen involucra un número de variables mucho menor que el total de variables descriptivas existentes. Todas las características antes mencionadas permiten la aplicación efectiva del método propuesto en conjuntos de datos de gran escala.

GEPMTR obtuvo resultados prometedores en los experimentos realizados. Sin embargo, la principal desventaja de GEPMTR radica en el análisis de un considerable número de hiperparámetros. Para futuros trabajos será importante expandir el estudio experimental, por ejemplo analizando diferentes valores para las probabilidades de los operadores.

#### IV. CONCLUSIONES

En este trabajo se ha presentado un método basado en GEP que resuelve el problema MTR mediante la técnica de regresión simbólica. Tanto la forma de codificación y evaluación de los individuos, como la posibilidad de paralelización, resultan en un método con un coste computacional aceptable y que permite ser usado en conjuntos de datos de gran escala.

Este trabajo corresponde con un estudio inicial, donde se busca analizar los beneficios del paradigma GEP para construir modelos de regresión multi-salida. En trabajos futuros, se estima mejorar algunos de los componentes del algoritmo, como un operador de selección que permita ajustar la presión selectiva. Por otro lado, sería interesante el desarrollo de *ensembles* usando GEPMTR.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto TIN2017-83445-P del Ministerio de Economía y Competitividad y Fondos FEDER, y además por la ayuda FPU del Ministerio de Educación FPU15/02948.

#### REFERENCIAS

- [1] H. Borchani, G. Varando, C. Bielza, and P. Larrañaga, "A survey on multi-output regression," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 5, no. 5, pp. 216–233, 2015.
- [2] E. Spyromitros-Xioufis, G. Tsoumakas, W. Groves, and I. Vlahavas., "Multi-target regression via input space expansion: Treating targets as inputs," *Machine Learning*, vol. 104, no. 1, pp. 55–98, 2016.
- [3] D. Kocev, S. Džeroski, M. D. White, G. R. Newell, and P. Griffioen, "Using single and multi-target regression trees and ensembles to model a compound index of vegetation condition," *Ecological Modelling*, vol. 220, no. 8, pp. 1159–1168, 2009.
- [4] D. Tuia, J. Verrelst, L. Alonso, F. Pérez-Cruz, and G. Camps-Valls, "Multioutput support vector regression for remote sensing biophysical parameter estimation," *IEEE Geoscience and Remote Sensing Letters*, vol. 8, no. 4, pp. 804–808, 2011.
- [5] A. Tsanas and A. Xifara, "Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools," *Energy and Buildings*, vol. 49, no. 560-567, 2012.
- [6] O. Reyes, C. Morell, and S. Ventura, "Evolutionary feature weighting to improve the performance of multi-label lazy algorithms," *Integrated Computer-Aided Engineering*, vol. 21, no. 4, pp. 339–354, 2014.
- [7] T. Similä and J. Tikka, "Input selection and shrinkage in multiresponse linear regression," *Computational Statistics & Data Analysis*, vol. 52, no. 1, pp. 406–422, 2007.
- [8] T. Aho, S. D. B. Ženko, and T. Elomaa, "Multi-target regression with rule ensembles," *Journal of Machine Learning Research*, vol. 373, pp. 2055–2066, 2009.
- [9] G. Melki, A. Cano, V. Kecman, and S. Ventura, "Multi-target support vector regression via correlation regressor chains," *Information Sciences*, vol. 415-416, pp. 53–69, 2017.
- [10] O. Reyes, A. Cano, H. Fardoun, and S. Ventura, "A locally weighted learning method based on a data gravitation model for multi-target regression," *International Journal of Computational Intelligence Systems*, vol. 11, pp. 282–295, 2018.
- [11] S. Stijven, E. Vladislavleva, A. Kordon, L. Willem, and M. E. Kotanchek, *Genetic Programming Theory and Practice XIII*. Cham: Springer, 2016, ch. Prime-Time: Symbolic Regression Takes Its Place in the Real World, pp. 241–260.
- [12] Y. Peng, C. Yuan, X. Qin, J. Huang, and Y. Shi, "An improved gene expression programming approach for symbolic regression problems," *Neurocomputing*, vol. 137, pp. 293–301, 2014.
- [13] C. Ferreira, "Gene expression programming: A new adaptive algorithm for solving problems," *Complex Systems*, vol. 13, pp. 87–129, 2001.
- [14] H. S. Lopes and W. R. Weinert, "Egipsys: An enhanced gene expression programming approach for symbolic regression problems," *International Journal of Applied Mathematics and Computer Science*, vol. 14, no. 3, pp. 375–384, 2004.
- [15] J. M. Moyano, E. Gibaja, and S. Ventura, "An evolutionary algorithm for optimizing the target ordering in ensemble of regressor chains," in *IEEE Congress on Evolutionary Computation*, 2017, pp. 2015–2021.
- [16] M. Friedman, "A comparison of alternative tests of significance for the problem of  $m$  rankings," *Annals of Mathematical Statistics*, vol. 11, no. 1, pp. 86–92, 1940.
- [17] S. Holm, "A simple sequentially rejective multiple test procedure," *Scandinavian journal of statistics*, pp. 65–70, 1979.
- [18] F. Wilcoxon, "Individual comparisons by ranking methods," *Biometrics Bulletin*, vol. 1, no. 6, pp. 80–83, 1945.



# Análisis de algoritmos de cuantificación basados en ajuste de distribuciones\*

Alberto Castaño  
*Centro de Inteligencia Artificial*  
*Universidad de Oviedo*  
 Gijón, España  
 castanoalberto@uniovi.es

Laura Morán-Fernández  
*Departamento de Computación*  
*Universidade da Coruña*  
 A Coruña, España  
 laura.moranf@udc.es

Jaime Alonso  
*Centro de Inteligencia Artificial*  
*Universidad de Oviedo*  
 Gijón, España  
 jalonso@uniovi.es

Verónica Bolón-Canedo  
*Departamento de Computación*  
*Universidade da Coruña*  
 A Coruña, España  
 veronica.bolon@udc.es

Amparo Alonso-Betanzos  
*Departamento de Computación*  
*Universidade da Coruña*  
 A Coruña, España  
 ciamparo@udc.es

Juan José del Coz  
*Centro de Inteligencia Artificial*  
*Universidad de Oviedo*  
 Gijón, España  
 juanjodelcoz@uniovi.es

**Resumen**—La cuantificación consiste en predecir la proporción de las distintas clases presentes en una muestra dada de ejemplos. Un tipo de algoritmos de cuantificación se basa en estimar y ajustar las distribuciones subyacentes del conjunto de entrenamiento y de la muestra a predecir. La diferencia clave entre los métodos propuestos reside en cómo estimar las distribuciones: usando los propios atributos o las predicciones dadas por un clasificador. Este artículo analiza ambas alternativas y propone dos nuevos algoritmos. La conclusión es que los métodos basados en usar las predicciones de un clasificador no son en general peores y en ciertos casos producen mejores estimaciones.

**Palabras clave:**—Cuantificación, Estimación de la prevalencia, Adaptación al dominio

## I. INTRODUCCIÓN

Existen diversas aplicaciones reales que demandan predecir la distribución de probabilidad de las clases en un conjunto de ejemplos. Formalmente, este problema se denomina cuantificación [1]. Ejemplos típicos son predecir la proporción de comentarios positivos y negativos en una red social sobre un acontecimiento o producto durante un período de tiempo [2], cuantificar la cantidad de células dañadas en un tejido [3] o predecir el porcentaje de incidencias de cada tipo en un centro de atención al usuario [1]. En estas aplicaciones no se requiere dar una predicción individual para cada ejemplo sino que basta con retornar una predicción única para toda la muestra.

Aunque a primera vista la cuantificación pueda verse como un subproducto de la clasificación, se pueden diseñar algoritmos de cuantificación que no se basen simplemente en agregar las predicciones dadas por un clasificador. Es el caso de los métodos que estiman y ajustan distribuciones de muestras de ejemplos. Si nos centramos en la cuantificación binaria, la idea consiste en estimar durante el entrenamiento la distribución de la clase positiva y negativa de alguna forma y, en el momento

de predecir una nueva muestra, estimar de la misma manera su distribución y aproximarla con una combinación de la distribución de la clase positiva y negativa dependiendo de la proporción de cada clase. La proporción que más aproxime ambas distribuciones será la que retorne el método [3], [4].

Se han propuesto sistemas basados en el ajuste de distribuciones no sólo en el campo de la cuantificación [3], sino también en otro problema relacionado como es el de los algoritmos de adaptación al dominio [5]. En estos últimos la idea es calcular la probabilidad a priori de las clases para actualizar un clasificador, sin necesidad de reentrenarlo, cuando la distribución de las clases cambia. El primer objetivo de este artículo es aunar y analizar ambas líneas de trabajo. Una diferencia clave entre ambas corrientes es cómo estimar las distribuciones. Mientras los algoritmos de adaptación al dominio se basan en estimar las distribuciones usando la información con la que se describen los ejemplos, los métodos de cuantificación proponen usar también las predicciones de un clasificador, asumiendo que ejemplos similares deben obtener predicciones parecidas. Un segundo objetivo de este artículo es comparar ambas alternativas. Asimismo, proponemos dos nuevos métodos que extienden algoritmos de adaptación al dominio, pero usando las predicciones de un clasificador.

Con todo ello, las contribuciones de este trabajo son: 1) presentar dos nuevos cuantificadores basados en ajustar distribuciones usando las predicciones de un clasificador, y 2) realizar un análisis experimental riguroso de los métodos basados en ajuste de distribuciones.

## II. CUANTIFICACIÓN BINARIA

Sea  $D = \{(\mathbf{x}_i, y_i)\}_{i=1}^n$  un conjunto de entrenamiento, donde  $\mathbf{x}_i$  es la representación de un ejemplo en el espacio de entrada  $\mathcal{X} \subset \mathbb{R}^d$ , e  $y_i \in \mathcal{Y} = \{-1, +1\}$  su clase. El objetivo de la cuantificación binaria es obtener un modelo,  $\hat{h}$ , que dado un conjunto de ejemplos sin etiquetar,  $T = \{\mathbf{x}_j\}_{j=1}^m$ ,

\*Esta investigación ha sido financiada en parte por el Ministerio de Economía y Competitividad (MINECO) y el Fondo Europeo de Desarrollo Regional (FEDER), a través del proyecto coordinado TIN2015-65069-C2.

prediga la proporción de la clase positiva y la clase negativa. Dado que ambas son complementarias, basta con predecir la proporción o prevalencia de la clase positiva  $\hat{p}$ , siendo la de la clase negativa  $1 - \hat{p}$ . En símbolos:  $\bar{h} : \mathbb{N}^{\mathcal{X}} \rightarrow [0, 1]$ , donde  $\mathbb{N}^{\mathcal{X}}$  denota un multi-conjunto de ejemplos, representado por el número de veces que cada posible ejemplo  $x \in \mathcal{X}$  aparece en dicho multi-conjunto.

La aproximación más sencilla para producir un cuantificador es la denominada Clasificar y Contar (CC), que consiste en entrenar un clasificador binario,  $h$ , clasificar con él todos los ejemplos de  $T$  y contar los ejemplos de cada clase:  $\hat{p}_{CC} = \bar{h}(T) = \frac{1}{m} \sum_{x_i \in T} I(h(x_i) = +1)$ , siendo  $I$  la función indicatriz. Sin embargo, los estudios muestran [6] que CC produce en general resultados subóptimos, especialmente cuando la distribución de las clases cambia significativamente entre el entrenamiento y la fase de predicción. Por ese motivo se han propuesto distintos algoritmos de cuantificación. Una revisión completa de ellos puede encontrarse en [7].

La cuantificación, por su propia definición, es uno de esos problemas de aprendizaje [8] en los que se sabe de antemano que la distribución de los datos cambia, es decir, que  $P_D(x, y) \neq P_T(x, y)$ , ya que es obvio que al menos cambia  $P_D(y) \neq P_T(y)$ <sup>1</sup>. La cuestión es determinar qué elementos de la distribución, entre  $P(x)$ ,  $P(x|y)$  y  $P(y|x)$ , se asume que no cambian para facilitar el aprendizaje. De hecho, la clave y el primer paso para diseñar un algoritmo de cuantificación es definir precisamente eso. La mayoría de los algoritmos de cuantificación están diseñados bajo la asunción de que  $P(x|y)$  se mantiene constante y que el resto de factores puede cambiar.

Esta asunción la sigue por ejemplo el método AC [1], que probablemente es el cuantificador más usado y que tomaremos como algoritmo básico de comparación en este estudio. La idea del método AC es que, dado que  $P(x|y)$  es constante, los ratios de verdaderos positivos,  $tpr$ , (*true positive rate*) y de falsos positivos,  $fpr$ , (*false positive rate*) del clasificador usado por el método CC serán constantes también, aunque cambie la distribución de probabilidad de las clases. Eso implica que la prevalencia que predice el método CC,  $\hat{p}_{CC}$ , se puede escribir en función de la prevalencia real  $p$ :

$$\hat{p}_{CC} = tpr \cdot p + fpr \cdot (1 - p). \quad (1)$$

Despejando  $p$  calculamos la prevalencia estimada por AC:

$$\hat{p}_{AC} = \frac{\hat{p}_{CC} - fpr}{tpr - fpr}. \quad (2)$$

En base a este desarrollo matemático, los pasos del método AC consisten en, primero, entrenar un clasificador y estimar su  $tpr$  y  $fpr$ , después usar el método CC para calcular  $\hat{p}_{CC}$  y finalmente aplicar (2) para obtener la predicción final,  $\hat{p}_{AC}$ . En teoría AC produce predicciones perfectas siempre que se cumpla que: 1)  $P(x|y)$  es constante y 2) las estimaciones del  $tpr$  y  $fpr$  son perfectas. Obviamente, es difícil que ambas condiciones se cumplan totalmente en problemas reales de una cierta complejidad, pero aún así el método suele ofrecer un buen rendimiento.

<sup>1</sup>Nótese que si  $P_D(y) = P_T(y)$  el problema de cuantificación sería trivial

### III. MÉTODOS BASADOS EN AJUSTE DE DISTRIBUCIONES

El enfoque para el problema de la cuantificación en el que se centra este artículo se basa en estimar y ajustar las distribuciones de entrenamiento y test. La idea fundamental consiste en modificar la distribución de entrenamiento, que abusando de notación denotaremos por  $D'$ , mediante una mezcla de la distribución de los ejemplos positivos,  $D^+$ , y la distribución de los negativos,  $D^-$ , en función de la prevalencia estimada de ambas clases, es decir,

$$D' = D^- \cdot (1 - \hat{p}) + D^+ \cdot \hat{p}. \quad (3)$$

El objetivo es tratar de aproximar  $D'$  lo más posible a la distribución estimada para el conjunto de test  $T$ . La Figura 1 trata de ilustrar esta idea. En la figura izquierda se observa la distribución de los ejemplos positivos y de los negativos de entrenamiento. En la parte derecha se muestra la distribución observable en el conjunto de test. Asumiendo de nuevo que  $P(x|y)$  es constante, y que por tanto las distribuciones de  $D^+$  y  $D^-$  cambiarán uniformemente en función de la prevalencia de las clases, el objetivo es minimizar la diferencia entre la distribución de test y la distribución modificada  $D'$ :

$$\min_{\hat{p}} \Delta(T, D') = \min_{\hat{p}} \Delta(T, D^- \cdot (1 - \hat{p}) + D^+ \cdot \hat{p}). \quad (4)$$

En el ejemplo de la Figura 1 es evidente que la prevalencia de la clase positiva en el conjunto de test es menor que la observada en los datos de entrenamiento y que por lo tanto, tenemos que disminuir ese valor para ajustar las distribuciones.

Los métodos basados en ajustar distribuciones comparten un marco común que consta de los siguientes elementos:

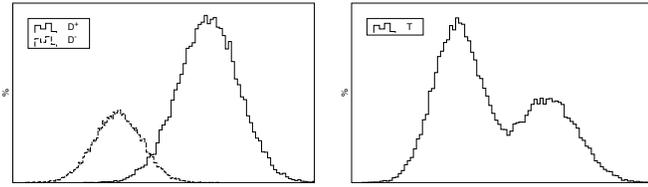
- una forma de estimar o representar las distribuciones,
- una medida  $\Delta$  para compararlas, y
- un método para calcular el mínimo de (4).

La diferencia entre los métodos que se estudian en este artículo está en alguno de estos tres elementos, pero nuestro interés principal es analizar las distintas formas usadas para estimar las distribuciones y en menor medida las métricas empleadas para compararlas.

En la Figura 1 se ha dejado deliberadamente sin etiquetar el eje horizontal para indicar que la distribución se puede representar usando diferentes datos. No obstante, hay dos corrientes fundamentales: usar la propia descripción de los ejemplos (lo que algunos métodos llaman usar la información de las  $X$ 's), o usar las predicciones dadas por un clasificador (usar las predicciones  $y$ )<sup>2</sup>. Las distribuciones de la Figura 1 podrían perfectamente representar funciones de densidad de probabilidad tanto del valor de un atributo del espacio de entrada  $\mathcal{X}$ , como de la probabilidad a posteriori dada por un clasificador de que un ejemplo pertenezca a la clase positiva,  $P(y = +1|x)$ .

En cuanto a la medida  $\Delta$ , hay múltiples opciones incluyendo normas como  $L1$  o  $L2$  y medidas de similitud o divergencia entre distribuciones de probabilidad como la divergencia

<sup>2</sup>No confundir con usar las etiquetas reales presentes en  $D$



(a) Distribuciones del cjo de entrenamiento (b) Distribución del cjo de test

Figura 1: Los métodos basados en comparación y ajuste estiman de alguna forma la distribución de (a) los ejemplos positivos y negativos disponibles en el entrenamiento,  $D^+$  y  $D^-$ , y (b) de los ejemplos de la muestra a predecir,  $T$ . Después tratan de ajustar la combinación de las distribuciones de  $D^+$  y  $D^-$  usando (3) para aproximar la distribución de  $T$

de Kullback-Leibler (KLD) y la distancia de Hellinger. En el artículo analizaremos las medidas que se han propuesto hasta ahora y propondremos dos nuevos métodos usando una función basada en distancias y otra en rankings.

### III-A. Ajuste Mediante la Distancia de Hellinger

Analizando la literatura de cuantificación, los métodos más relevantes basados en ajuste de distribuciones son los propuestos en [3]. Se trata de dos métodos basados en la distancia de Hellinger (HD) para comparar las distribuciones, donde éstas se representan mediante histogramas: en un caso del valor de los atributos (versión llamada HDX) y en el otro del valor de las predicciones de un clasificador (HDy). Usar histogramas hace que estos métodos tengan un hiperparámetro,  $b$ , que es el número de intervalos o *bins* usados en los histogramas.

Usando la definición de la distancia de Hellinger para el caso discreto multivariante, y aplicando (3) para representar  $D'$ , resulta en el siguiente problema a minimizar:

$$\min_{\hat{p}} \frac{1}{d} \sum_{l=1}^d \sqrt{\sum_{k=1}^b \left( \sqrt{\frac{|T_{k,l}|}{m}} - \sqrt{\frac{|D_{k,l}^-|}{n^-} (1-\hat{p}) + \frac{|D_{k,l}^+|}{n^+} \hat{p}} \right)^2}, \quad (5)$$

donde  $n^-$  y  $n^+$  son el número de ejemplos en  $D^-$  y  $D^+$  respectivamente y  $|T_{k,l}|/m$ ,  $|D_{k,l}^-|/n^-$  y  $|D_{k,l}^+|/n^+$  son la proporción de ejemplos de  $T$ ,  $D^-$  y  $D^+$  que pertenece al bin  $k$  en la dimensión  $l$ . En el caso de HDy, solamente tenemos una dimensión que se corresponde con las predicciones del clasificador, luego el primer sumatorio desaparece.

Los autores proponen una búsqueda lineal, variando  $\hat{p}$  en el rango  $[0, 1]$  en pequeños incrementos, para resolver (5). Sin embargo, la solución se puede hallar analíticamente, con más precisión y menos coste computacional, teniendo en cuenta la equivalencia entre la distancia de Hellinger y el coeficiente de Bhattacharyya,  $HD(T, D') = \sqrt{1 - BC(T, D')}$  [9], y resolviendo el siguiente problema de optimización:

$$\begin{aligned} \min_{\pi} \quad & 1 - \sum_k \sqrt{T_k(D'\pi)_k}, \\ \text{s.a.} \quad & \sum \pi = 1, \quad \pi_i \geq 0, \end{aligned} \quad (6)$$

donde, sobrecargando la notación, definimos:

- $T$  como una matriz con  $bd \times 1$  en el caso del método HDX, con las proporciones de los bins del primer atributo en las  $b$  primeras filas, y así sucesivamente con el resto de atributos, y en el caso de HDy con solamente  $b$  filas y una columna con las proporciones de cada bin calculadas con las predicciones del clasificador,
- $D'$  es una matriz de  $bd \times 2$  en el caso del método HDX, y  $b \times 2$  en el caso del HDy, con idéntica estructura a la matriz  $T$ , donde las dos columnas representan, en este orden, las proporciones de la clase negativa y positiva, y
- $\pi$  una matriz  $2 \times 1$  con dos variables,  $\pi_1$  la prevalencia de la clase negativa, y  $\pi_2$  la de la positiva,  $\hat{p}$ .

Este problema puede resolverse con cualquier librería de optimización convexa; nosotros empleamos `cvxpy` para Python.

En teoría, la ventaja de HDX es usar directamente la información disponible en los atributos con los que se representan los ejemplos, lo cual puede ser una desventaja en espacios de alta dimensionalidad, o cuando los problemas dependan mucho de la interacción entre los valores de los atributos, ya que estos se consideran de forma en cierto modo independiente al calcular la HD, como hemos descrito anteriormente. La ventaja del método HDy es que resume en una sola dimensión, a través de un clasificador, la distribución de los ejemplos, asumiendo que ejemplos parecidos deben obtener predicciones similares. La desventaja del método HDy es que el clasificador debe entrenarse adecuadamente y las estimaciones de las predicciones de los ejemplos deben hacerse no en reescritura, sino usando validaciones cruzadas con un alto número de particiones para evitar el sobreajuste en las predicciones.

### III-B. Ajuste Mediante la Distancia Energy

Varios métodos de adaptación al dominio [5], [10] se basan en calcular la nueva distribución de las clases (denominadas probabilidades a priori en este contexto). La idea es usar esas nuevas probabilidades a priori para ajustar el clasificador disponible sin necesidad de reentrenarlo. Es obvio que dichos métodos también pueden usarse como algoritmos de cuantificación, aunque su objetivo sea otro bien distinto. En la literatura de adaptación al dominio es habitual que la comparación entre las distribuciones de entrenamiento y test se haga solamente usando el valor de los atributos [4], [11]. Dichos métodos plantean los mismos problemas que comentamos anteriormente para el método HDX: a veces es complejo calcular las densidades antes de compararlas. No obstante, siguiendo ese enfoque, recientemente se ha publicado un método [12] que destaca entre los propuestos en ese campo ya que es computacionalmente muy eficiente y tiene un mejor rendimiento que otros métodos anteriores [4].

Dicho algoritmo, que denotaremos por EDX, se basa en minimizar la distancia *Energy* (ED) entre la distribución de  $T$  y la distribución modificada  $D'$  definida por:

$$\begin{aligned} \min_{\hat{p}} \quad & 2 \cdot \mathbb{E}_{\mathbf{x}_j \sim T, \mathbf{x}_i \sim D'} \|\mathbf{x}_j - \mathbf{x}_i\| \\ & - \mathbb{E}_{\mathbf{x}_j, \mathbf{x}'_j \sim T} \|\mathbf{x}_j - \mathbf{x}'_j\| - \mathbb{E}_{\mathbf{x}_i, \mathbf{x}'_i \sim D'} \|\mathbf{x}_i - \mathbf{x}'_i\|, \end{aligned} \quad (7)$$

donde  $\|\cdot\|$  representa la distancia euclídea. Nótese que el segundo término puede suprimirse al ser independiente de  $\hat{p}$  debido a que solo interviene la distribución de  $T$ . Omitimos aquí la derivación matemática para resolver este problema ya que es similar al que detallaremos en la sección siguiente.

#### IV. MÉTODOS PROPUESTOS

Nuestra primera propuesta consiste en hacer el método complementario al EDX, que llamaremos EDy y que emplea las predicciones de un clasificador  $h$  en lugar de los atributos que definen  $\mathcal{X}$ . Para ello debemos minimizar la expresión:

$$\begin{aligned} \min_{\hat{p}} \quad & 2 \cdot \mathbb{E}_{\mathbf{x}_j \sim T, \mathbf{x}_i \sim D^-} \|h(\mathbf{x}_j) - h(\mathbf{x}_i)\|_1 \\ & - \mathbb{E}_{\mathbf{x}_i, \mathbf{x}'_i \sim D^+} \|h(\mathbf{x}_i) - h(\mathbf{x}'_i)\|_1. \end{aligned} \quad (8)$$

Si desdoblamos ambos términos aplicando (3) tenemos

$$\begin{aligned} \min_{\hat{p}} \quad & 2 \cdot (1 - \hat{p}) \cdot \mathbb{E}_{\mathbf{x}_j \sim T, \mathbf{x}_i \sim D^-} \|h(\mathbf{x}_j) - h(\mathbf{x}_i)\|_1 \\ & + 2 \cdot \hat{p} \cdot \mathbb{E}_{\mathbf{x}_j \sim T, \mathbf{x}_i \sim D^+} \|h(\mathbf{x}_j) - h(\mathbf{x}_i)\|_1 \\ & - (1 - \hat{p})^2 \cdot \mathbb{E}_{\mathbf{x}_i, \mathbf{x}'_i \sim D^-} \|h(\mathbf{x}_i) - h(\mathbf{x}'_i)\|_1 \\ & - 2 \cdot \hat{p} \cdot (1 - \hat{p}) \mathbb{E}_{\mathbf{x}_i \sim D^+, \mathbf{x}'_i \sim D^-} \|h(\mathbf{x}_i) - h(\mathbf{x}'_i)\|_1 \\ & - \hat{p}^2 \cdot \mathbb{E}_{\mathbf{x}_i, \mathbf{x}'_i \sim D^+} \|h(\mathbf{x}_i) - h(\mathbf{x}'_i)\|_1. \end{aligned} \quad (9)$$

En la práctica podemos aproximar cada esperanza usando los correspondientes muestras de ejemplos disponibles:

$$\mathbb{E}_{\substack{\mathbf{x}_j \sim T \\ \mathbf{x}_i \sim D^-}} \dots \approx \mu_{T, D^-} = \frac{1}{mn} \sum_{\mathbf{x}_j \in T} \sum_{\mathbf{x}_i \in D^-} \|h(\mathbf{x}_j) - h(\mathbf{x}_i)\|_1. \quad (10)$$

Sustituyendo todos los términos tenemos

$$\begin{aligned} \min_{\hat{p}} \quad & 2(1 - \hat{p})\mu_{T, D^-} + 2\hat{p}\mu_{T, D^+} \\ & - (1 - \hat{p})^2\mu_{D^-, D^-} - 2\hat{p}(1 - \hat{p})\mu_{D^-, D^+} - \hat{p}^2\mu_{D^+, D^+}, \end{aligned} \quad (11)$$

un problema fuertemente convexo [12] en el que derivando e igualando a cero obtenemos que

$$\hat{p} = \frac{\mu_{T, D^-} - \mu_{T, D^+} - \mu_{D^-, D^-} + \mu_{D^-, D^+}}{-\mu_{D^-, D^-} + 2\mu_{D^-, D^+} - \mu_{D^+, D^+}}. \quad (12)$$

El segundo método propuesto trata de completar el tipo de medidas consideradas para comparar distribuciones. Por un lado tenemos una medida basada en histogramas (Hellinger), una segunda basada en distancias (*Energy*) y se podría considerar una tercera opción que se basase en rankings, por ejemplo usando el criterio Cramér-von Mises (CvM). Después de analizar varias alternativas que utilizaban medidas derivadas de CvM [13], observamos que planteaban ciertos problemas en el contexto de la cuantificación binaria. El principal es que los errores en los rankings dados por un clasificador no son simétricos respecto a las clases: la clase positiva tiende a dar valores más altos, por ejemplo, al usar un clasificador probabilístico que devuelva  $P(y = +1|x)$ , lo que hace que los errores sean mayores y la medida sea sesgada hacia esa clase. Por ese motivo, finalmente decidimos usar el enfoque propuesto en [14] y crear el método CvMy que consiste en:

1. Calcular un ranking conjunto de los ejemplos disponibles en  $T$ ,  $D^-$  y  $D^+$ ,

2. Utilizar la ED para ajustar las distribuciones.

Es decir, aplicamos el mismo algoritmo que en el método EDy, pero en lugar de calcular la distancia entre las predicciones, calculamos la distancia entre los rankings de las predicciones. En este caso  $\mu_{T, D^-}$  se calcularía como

$$\mu_{T, D^-} = \frac{1}{mn} \sum_{\mathbf{x}_j \in T} \sum_{\mathbf{x}_i \in D^-} \|r(h(\mathbf{x}_j)) - r(h(\mathbf{x}_i))\|, \quad (13)$$

donde  $r(h(\mathbf{x}))$  nos devuelve la posición en el ranking conjunto para todos los ejemplos disponibles, tanto del conjunto de entrenamiento como de la muestra de test a predecir. Luego la diferencia entre EDy y CvMy es simplemente que en un caso usamos las distancias entre las predicciones y en otro caso las diferencias entre los rankings de esas predicciones.

#### V. EXPERIMENTOS

El objetivo de los experimentos<sup>3</sup> era comparar los métodos descritos en las secciones III y IV sobre varios conjuntos de datos. Se prestó especial atención a aquellos pares de métodos que, empleando la misma técnica, actúan sobre  $X$  ó  $y$ . Otro aspecto a analizar es la diferencia entre los métodos que utilizan distintas métricas para ajustar las distribuciones. Con el fin de tener una base de comparación, se incluyó el método AC. Para realizar los experimentos se emplearon 41 conjuntos de datos. Entre ellos se encuentran conjuntos binarios y otros que son versiones binarizadas de conjuntos originalmente multiclase. Así, por ejemplo, el conjunto *balance.1* es un conjunto binario en el que la clase 1 original es la clase positiva, formando el resto la clase negativa.

Los métodos que necesitan un clasificador (AC, HDy, EDy y CvMy) fueron entrenados garantizando que usen exactamente los mismos clasificadores. Como algoritmo de clasificación se optó por utilizar *Random Forest* (RF) con salida probabilística para obtener modelos no lineales. La representación usada por el método HDy se generó mediante 8 *bins* por ser el valor que da mejores resultados en estudios previos [15]. Respecto a la hiperparametrización de RF, se llevó a cabo una búsqueda donde la profundidad variaba entre [1, 5, 10, 15, 20, 25, 30], el número de árboles entre [9, 18, 27, 36, 45, 54, 63], y el número mínimo de ejemplos para los nodos hoja entre [1, 2, 4, 6, 8, 10]. Dicha búsqueda se realizó optimizando la media geométrica mediante una validación cruzada de tres particiones de tal forma que se obtuvieran buenos clasificadores incluso cuando las clases no estuvieran balanceadas.

Todos los modelos se entrenaron sobre las mismas particiones de los conjuntos de datos en subconjuntos de entrenamiento y test, usando el 70 % de los datos para entrenar y el 30 % restante para testear el modelo, haciendo 20 repeticiones. Con cada partición de test se generaron a su vez 50 conjuntos aleatorios con diferente prevalencia mediante muestreo con reemplazamiento. La Tabla I presenta el error absoluto medio de las 1000 muestras totales de test,  $\frac{1}{1000} \sum_{i=1}^{1000} |\hat{p}_i - p_i|$ .

<sup>3</sup>Con el fin de facilitar la reproducibilidad de estos experimentos, los conjuntos de datos, el código y los resultados obtenidos están disponibles en <http://github.com/albertorepo/analisis-cuantificacion>.



Tabla I: Error absoluto medio para cada método sobre cada conjunto de datos

conjunto	AC	CvMy	EDX	EDy	HDX	HDy
acute.a	<b>0.037108</b>	0.063550	0.043139	0.045118	0.055545	0.038207
acute.b	<b>0.032788</b>	0.066146	0.036890	0.041999	0.041406	0.054910
balance.1	0.035783	0.033945	<b>0.023380</b>	0.030977	0.031761	0.029968
balance.3	0.036954	0.041549	0.031478	0.036346	0.038860	<b>0.028690</b>
breast-cancer	<b>0.016127</b>	0.041405	0.021433	0.019083	0.020661	0.016980
cmc.1	0.086332	0.078364	0.078307	0.076136	0.069633	<b>0.066261</b>
cmc.2	0.107941	0.119897	<b>0.067238</b>	0.115609	0.070623	0.108277
cmc.3	0.123313	0.102359	0.097244	0.094503	<b>0.089708</b>	0.099939
coil	<b>0.074547</b>	0.088761	0.091519	0.084081	0.152487	0.111920
ctg.1	<b>0.015548</b>	0.024147	0.029277	0.017414	0.039771	0.015466
ctg.2	0.029396	0.034666	0.033221	0.029420	0.035380	<b>0.027457</b>
ctg.3	0.036554	0.034602	0.037974	<b>0.028830</b>	0.072301	0.029866
default_credit	0.019715	0.022824	0.019998	0.020298	<b>0.019029</b>	0.022613
diabetes	0.072729	0.054864	0.059925	<b>0.053669</b>	0.079258	0.057511
german	0.087824	0.094541	<b>0.078250</b>	0.094154	0.100175	0.108456
haberman	0.243842	0.249899	<b>0.166582</b>	0.235816	0.263772	0.210012
ionsphere	<b>0.048585</b>	0.066306	0.060841	0.055436	0.055167	0.051017
iris.1	0.002824	0.093470	<b>0.016286</b>	0.019482	0.019413	0.036264
iris.2	0.055456	0.072105	0.083458	<b>0.048620</b>	0.050365	0.060695
iris.3	0.056763	0.066537	0.048433	0.046074	<b>0.040583</b>	0.075169
lettersH	0.020787	0.026393	0.027549	0.025537	0.024807	<b>0.016682</b>
mammographic	0.055443	0.049573	0.047413	0.044584	0.040516	<b>0.039722</b>
normtrans	0.126085	0.115678	<b>0.083582</b>	0.111233	0.184914	0.140455
normwine.1	0.044364	0.053990	<b>0.031585</b>	0.037656	0.036819	0.041440
normwine.2	0.050073	0.052678	<b>0.041247</b>	0.044185	0.067116	0.052616
normwine.3	0.043011	0.058478	<b>0.037641</b>	0.037738	0.058761	0.059418
pageblocks.5	0.042875	0.045982	0.056530	0.042546	0.116209	<b>0.037511</b>
phoneme	0.016554	0.019391	0.020960	0.015883	0.017325	<b>0.012115</b>
semeion.8	0.058507	0.058614	0.086534	0.058085	0.053439	<b>0.042278</b>
sonar	0.113939	0.108738	<b>0.103082</b>	0.107576	0.126948	0.110015
spambase	<b>0.008127</b>	0.015965	0.011639	0.010721	0.020363	0.008359
spectf	0.184524	0.162914	0.105445	0.150938	<b>0.088333</b>	0.134393
tictactoe	<b>0.048306</b>	0.061411	0.081694	0.056250	0.078846	0.048768
transfusion	0.107033	0.132669	<b>0.079578</b>	0.116017	0.162173	0.139883
wdbc	0.022888	0.030576	0.025309	0.016853	0.027982	<b>0.016830</b>
wine-quality-red	0.045189	0.037138	0.042694	<b>0.035102</b>	0.047469	0.037303
wine-quality-white	0.031770	0.030004	<b>0.028205</b>	0.028864	0.029644	0.025918
wine.1	0.037356	0.051096	0.034395	<b>0.033942</b>	0.036904	0.044647
wine.2	0.044871	0.056931	0.051078	<b>0.041804</b>	0.068114	0.051526
wine.3	0.037569	0.057219	0.036618	<b>0.035190</b>	0.048123	0.038674
yeast	0.060799	0.062919	<b>0.051120</b>	0.063225	0.060161	0.052552

El método ganador para cada conjunto se destaca en negrita. Puede verse que no hay un método que gane claramente a los demás. Tampoco se observan diferencias concluyentes entre las formas de estimar las distribuciones ni entre las medidas para ajustarlas. Entre los métodos propuestos, el algoritmo EDy es superior, siendo competitivo con los algoritmos previos, lo que parece no ocurrir en el caso del método CvMy.

Para analizar los resultados desde un punto de vista estadístico hemos aplicado análisis bayesianos en lugar de los tradicionales tests de contraste de la hipótesis nula ya que estamos de acuerdo con las desventajas de estos últimos apuntadas en [16]. Previamente a la aplicación de estos tests, es necesario definir la *región de equivalencia práctica* (*rope*, por sus siglas en inglés): dos métodos se consideran prácticamente equivalentes si la diferencia dada una métrica no supera un cierto umbral. En nuestro caso, consideramos dos cuantificadores equivalentes si la diferencia en error absoluto es menor del 1%. La elección del error absoluto como medida de evaluación se debe a que es una métrica acotada entre 0 y 1 y por lo tanto, *rope* puede definirse como un porcentaje de variación

dentro de ese intervalo. Para otras métricas como la KLD no sería trivial la elección de tal región, dado que su valor tiene un rango infinito, además de una difícil interpretación práctica. Una vez fijado el valor de *rope* es posible realizar el análisis para cada par de métodos tanto en cada conjunto individual (Tabla II) como para todos los conjuntos usando un test jerárquico [16] (Tabla III). En el primer caso podemos calcular la probabilidad de cada una de las tres posibilidades: que gane uno de los dos cuantificadores o que los resultados caigan en la zona de equivalencia. Cuando una de esas tres probabilidades es mayor que el 95% consideramos que hay una diferencia significativa en favor de esa alternativa, y si no, lo marcamos como un conjunto *sin decisión*. Analizando la Tabla II vemos una ligera ventaja en favor de los métodos *y* frente a los métodos *X*, más clara en el caso de HDy frente a HDX que en la comparación EDy vs. EDX. En el caso de CvMy, es inferior a HDy y EDy, especialmente frente al segundo. En cambio EDy obtiene mejores resultados que el resto de métodos excepto HDy, pero la diferencia entre ambos es pequeña. Si analizamos los resultados a nivel global con el

Tabla II: Número de conjuntos para los que el test bayesiano decide que existe diferencia significativa ( $\geq 95\%$ )

Par ( $m_1$ - $m_2$ )	$m_1$	$rope$	$m_2$	Sin decisión
EDX-AC	16	7	16	2
EDX-CvMy	17	11	7	6
EDX-EDy	9	16	12	4
EDX-HDX	10	15	7	9
EDX-HDy	10	15	14	2
EDy-AC	14	14	9	4
EDy-CvMy	11	24	0	6
EDy-HDX	15	11	9	6
EDy-HDy	8	13	10	10
HDX-AC	11	9	17	4
HDX-CvMy	16	9	13	3
HDX-HDy	6	13	19	3
HDy-AC	11	19	11	0
HDy-CvMy	15	15	6	5
AC-CvMy	16	11	9	5

Tabla III: Resultados del test bayesiano jerárquico

Par ( $m_1$ - $m_2$ )	$P(m_1 \gg m_2)$	$P(rope)$	$P(m_2 \gg m_1)$
EDX-AC	0.537	0.000	0.463
EDX-CvMy	0.970	0.013	0.018
EDX-EDy	0.239	0.252	0.509
EDX-HDX	0.347	0.598	0.055
EDX-HDy	0.342	0.009	0.649
EDy-AC	0.523	0.202	0.275
EDy-CvMy	0.286	0.714	0.000
EDy-HDX	0.768	0.134	0.099
EDy-HDy	0.105	0.744	0.150
HDX-AC	0.162	0.002	0.837
HDX-CvMy	0.706	0.001	0.293
HDX-HDy	0.022	0.005	0.973
HDy-AC	0.451	0.072	0.477
HDy-CvMy	0.971	0.005	0.024
AC-CvMy	0.814	0.005	0.180

test jerárquico (Tabla III) vemos que hay pocas diferencias significativas (HDy vs. CvMy, HDy vs. HDX y EDy vs. CvMy). Se observa de nuevo la ligera ventaja de los métodos  $y$ , EDy y HDy, frente a EDX y HDX. Estos datos son un resumen de la distribución de las diferencias entre cada par de métodos. La forma de la distribución puede verse mediante un gráfico simplex (Figura 2). Por ejemplo, es interesante ver que en la comparación EDy-CvMy la nube de puntos está muy alejada del vértice de CvMy, a pesar de que la diferencia no resulte significativa, mostrando una superioridad clara.

## VI. CONCLUSIONES

Este trabajo tenía como principal objetivo realizar un análisis comparativo entre diferentes algoritmos de cuantificación basados en ajuste de distribuciones. Los resultados experimentales obtenidos muestran que los métodos basados en las  $y$ 's, es decir, en el uso de clasificadores, no son en general peores, obteniendo mejores estimaciones en ciertas ocasiones. En cuanto a los métodos propuestos, EDy se configura como una buena alternativa, pero no así el algoritmo propuesto basado en ranking, CvMy. Como futura línea de investigación, se plantea la aplicación de algún algoritmo de selección de características en los métodos  $X$  para tratar de obtener un subconjunto con los mejores atributos. Además, sería interesante realizar una búsqueda de características en los problemas

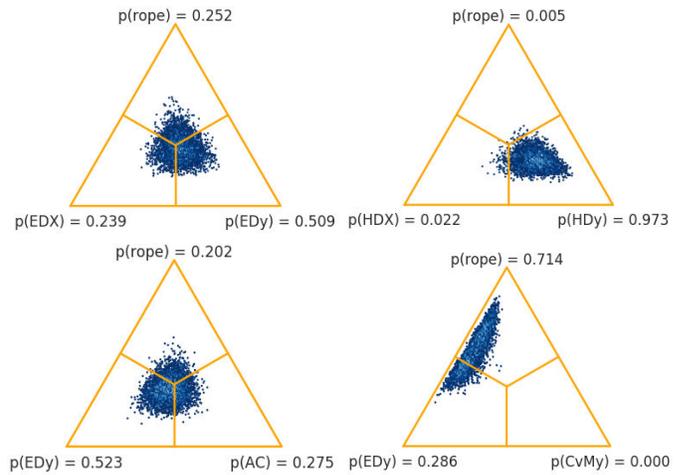


Figura 2: Gráficos simplex de la comparación mediante el test jerárquico bayesiano de varios pares de métodos

(alta dimensionalidad de entrada, presencia de ruido, etc.), que puedan implicar un mejor comportamiento en cada método.

## REFERENCIAS

- [1] G. Forman, "Quantifying counts and costs via classification," *Data Mining and Knowledge Discovery*, vol. 17, no. 2, pp. 164–206, 2008.
- [2] P. González, J. Díez, N. Chawla, and J. J. del Coz, "Why is quantification an interesting learning problem?" *Progress in Artificial Intelligence*, pp. 1–6, 2016.
- [3] V. González-Castro, R. Alaiz-Rodríguez, and E. Alegre, "Class distribution estimation based on the hellinger distance," *Information Sciences*, vol. 218, pp. 146–164, 2013.
- [4] M. Sugiyama, T. Kanamori, T. Suzuki, M. C. du Plessis, S. Liu, and I. Takeuchi, "Density-difference estimation," *Neural Computation*, vol. 25, no. 10, pp. 2734–2775, 2013.
- [5] A. Margolis, "A literature review of domain adaptation with unlabeled data," University of Washington, Tech. Rep., 2011.
- [6] J. Barranquero, P. González, J. Díez, and J. J. del Coz, "On the study of nearest neighbor algorithms for prevalence estimation in binary problems," *Pattern Recognition*, vol. 46, no. 2, pp. 472–482, 2013.
- [7] P. González, A. Castaño, N. V. Chawla, and J. J. del Coz, "A review on quantification learning," *ACM Computing Surveys*, vol. 50, no. 5, pp. 74:1–74:40, 2017.
- [8] J. Moreno-Torres, T. Raeder, R. Alaiz-Rodríguez, N. Chawla, and F. Herrera, "A unifying view on dataset shift in classification," *Pattern Recognition*, vol. 45, no. 1, pp. 521–530, 2012.
- [9] A. Firat, "Unified framework for quantification," *arXiv preprint arXiv:1606.00868*, 2016.
- [10] H. Daume III and D. Marcu, "Domain adaptation for statistical classifiers," *JAIR*, vol. 26, pp. 101–126, 2006.
- [11] A. Iyer, S. Nath, and S. Sarawagi, "Maximum mean discrepancy for class ratio estimation: Convergence bounds and kernel selection." in *ICML*, 2014, pp. 530–538.
- [12] H. Kawakubo, M. C. Du Plessis, and M. Sugiyama, "Computationally efficient class-prior estimation under class balance change using energy distance," *IEICE Tran. on Inf. and Sys.*, vol. 99, pp. 176–186, 2016.
- [13] L. Morán-Fernández, V. Bolón-Canedo, and A. Alonso-Betanzos, "A distributed approach for classification using distance metrics," in *ESANN*, 2017.
- [14] J. Curry, X. Dang, and H. Sang, "A rank-based Cramér-von-Mises-type test for two samples," *arXiv preprint arXiv:1802.06332*, 2018.
- [15] P. Pérez-Gállego, J. R. Quevedo, and J. J. del Coz, "Using ensembles for problems with characterizable changes in data distribution: A case study on quantification," *Information Fusion*, vol. 34, pp. 87–100, 2017.
- [16] A. Benavoli, G. Corani, J. Demšar, and M. Zaffalon, "Time for a change: a tutorial for comparing multiple classifiers through bayesian analysis," *Journal of Machine Learning Research*, vol. 18, no. 77, pp. 1–36, 2017.



# $k$ -Vecinos más Cercanos Difuso para Clasificación Monotónica

Sergio González, Salvador García, Francisco Herrera  
 Dept. de Ciencias de la Computación e Inteligencia Artificial  
 Universidad de Granada  
 Granada, España  
 {sergiogvz, salvagl, herrera}@decsai.ugr.es

Sheng-Tun Li  
 Dept. de Gestión Industrial y de Información  
 Universidad Nacional Cheng Kung  
 Tainan, Taiwan  
 stli@mail.ncku.edu.tw

Robert John  
 Escuela de Ciencias de la Computación  
 Universidad de Nottingham  
 Nottingham, Reino Unido  
 robert.john@nottingham.ac.uk

**Resumen**—La clasificación con restricciones monotónicas proviene de una necesidad de algunos problemas reales, en los que la variable de salida no disminuyen con un aumento de las entrada, o viceversa. Los conjuntos de datos reales con frecuencia tiene una gran cantidad de ruido de clase. Este incrementa el número de violaciones monotónicas y repercute negativamente en el rendimiento de los clasificadores. Por lo que, algunos métodos deben recurrir a técnicas de re-etiquetado que pueden alterar el conocimiento del problema. Además, la inclusión de estas restricciones obligan a los clasificadores a diversificar sus objetivos entre precisión y monotonicidad.

Con esta contribución, se propone un nuevo modelo basado en los  $k$ -Vecinos más Cercanos Difuso para la clasificación con restricciones monotónicas, MonF $k$ NN. Este clasificador incorpora un nuevo cálculo de pertenencias difusas, que lo dota de robustez frente ruido monotónico sin necesidad de re-etiquetado. Asimismo, se ha diseñado para ser adaptable a las diferentes necesidades del problema. Tras varios estudios experimentales, ha demostrado ser tremendamente más preciso igualando el grado de monotonicidad de los mejores métodos de la literatura.

**Palabras Clave**—Ciencia de datos, aprendizaje perezoso, vecinos más cercanos difuso, restricciones monotónicas, clasificación ordinal, regresión ordinal

## I. INTRODUCCIÓN

La evaluación de activos o individuos [1], [2] tienen como objetivo determinar los artículos más valiosos según sus virtudes, es decir, la clasificación en etiquetas ordinales según sus atributos ordinales. Además, estas aplicaciones suelen conllevar una restricción monotónica entre las entradas y la clase. Es decir, la predicción de clase de un individuo no debe disminuir con un mejor valor para una determinada variable, fijando el resto. Estos problemas se conocen como clasificación con restricciones de monotonicidad [3] y la ruptura de estas, como violaciones de monotonicidad.

Este trabajo ha contado con el apoyo del Proyecto Español TIN2017-89517-P y una beca de investigación (FPU) otorgada a S. González por el MECED.

Estas tareas de aprendizaje exigen otros requisitos además de modelos precisos, como la consistencia monótona de las predicciones o la minimización de los errores de clasificación. Sin embargo, estos otros objetivos pueden perjudicar la precisión. Por lo tanto, se debe buscar un equilibrio justo entre las diferentes necesidades de cada problema.

En estos últimos años, se ha diseñado nuevos algoritmos que consideran estas restricciones [1], [3]–[6]. El aprendizaje basado en la instancia ha demostrado ser una buena aproximación para la clasificación monotónica [4], [6]. Sin embargo, algunos de estos métodos, como la variante monotónica de  $k$ -Vecinos más Cercanos [4] (M $k$ NN), necesitan aprender de un conjunto completamente monótono para asegurar predicciones monótonas. Esta circunstancia rara vez se cumple en conjuntos reales, donde el ruido y las discrepancias son comunes. Por ello, se hace uso de estrategias de re-etiquetado que alteran las etiquetas de clase de algunos ejemplos forzando un conjunto monotónico [4].

En clasificación estándar, la versión difusa de los  $k$ -Vecinos más Cercanos [7] (F $k$ NN) es un método muy sólido con un gran rendimiento, gracias a su alta robustez al ruido [8]. En esta contribución, se presenta un nuevo modelo diseñado sobre F $k$ NN con nociones de M $k$ NN para tener en cuenta las restricciones de monotonicidad, llamado MonF $k$ NN. La robustez de F $k$ NN se ha adaptado para reducir el impacto de las violaciones monotónicas sin la necesidad de re-etiquetado. Adicionalmente, se han añadido otras técnicas para tratar las pertenencias de instancia de una manera más adecuada según la monotonicidad. Nuestra propuesta MonF $k$ NN es un clasificador flexible que cubre diferentes necesidades de monotonicidad y precisión, con buen equilibrio entre ambos, ajustando sus parámetros.

Este documento está organizado de la siguiente manera. En la Sección II, presentamos el problema de la clasificación con restricciones monotónicas y los métodos relacionados con

nuestra propuesta. La sección III está dedicada a explicar con lujo de detalle la propuesta MonFkNN. En la Sección IV, se presenta el marco experimental utilizado en los diferentes estudios empíricos. La sección V plantea tres estudios experimentales: un análisis sobre los parámetros de nuestro método y sus dos configuraciones más relevantes, una profunda comparación con el Estado-del-Arte y un estudio de la robustez de MonFkNN frente al ruido. Finalmente, en la Sección VI, se presentan las principales conclusiones de este estudio.

## II. PRELIMINARES

En esta sección, se introducen los preliminares sobre los que se construye este trabajo.

### II-A. Clasificación Monotónica

La clasificación monotónica tiene como objetivo predecir la etiqueta de la clase  $y$  a partir del vector de la característica de entrada  $x$ , donde  $y \in \mathcal{Y} = \{\mathcal{L}_1, \mathcal{L}_2, \dots, \mathcal{L}_c\}$ ,  $x \in \mathcal{X} \subseteq \mathbb{R}^K$ . Como propiedad principal, los atributos y sus predicciones están monotónicamente restringidos por conocimiento previo del problema, es decir,  $x \succeq x' \rightarrow f(x) \geq f(x')$  [9], donde  $x \succeq x'$  implica  $\forall_{j=1, \dots, K}, x_j \geq x'_j$ , esto es,  $x$  domina  $x'$ . Por lo tanto, el objetivo principal es construir clasificadores que no violen estas restricciones, conocidos como clasificadores monótonos.

Se pueden distinguir dos tipos diferentes de clasificadores monotónicos: los modelos monotónicos aproximados, que minimizan el número de violaciones monotónicas en sus decisiones, y los clasificadores monotónicos puros, cuyas predicciones son siempre monotónicas en relación con el entrenamiento. Esto último es difícil de lograr, especialmente en aplicaciones de la vida real, donde los conjuntos de datos de formación rara vez son puramente monótonos. Para ser considerado monotónico, un conjunto de datos debe tener todos sus pares de instancias monotónicas entre sí [6]:  $x_i \succeq x_j \rightarrow y_i \geq y_j, \forall_{i,j}$ .

### II-B. $k$ -Vecinos más Cercanos Monotónico

La aproximación de los  $k$ -Vecinos más Cercanos para la clasificación monotónica [4] (MkNN) modifica la regla estándar del vecino más cercano para evitar violaciones monotónicas en sus predicciones. Para ello, MkNN calcula para cada nuevo ejemplo  $x_i$  el rango  $r_i = [y_{min}, y_{max}]$  de etiquetas de clase válidas, que satisfagan las restricciones monotónicas. El  $y_{min}$  inferior de  $r_i$  se calcula como la etiqueta de clase más alta de todas las instancias por debajo del ejemplo  $x_i$ . Análogamente, el límite superior  $y_{max}$  es la etiqueta de clase mínima de las instancias superiores a  $x_i$  (véase la Ec. 1).

$$r_i = \begin{cases} y_{min} = \max\{y | (x, y) \in \mathcal{D} \wedge x_i \succeq x\} \\ y_{max} = \min\{y | (x, y) \in \mathcal{D} \wedge x \succeq x_i\} \end{cases} \quad (1)$$

Se pueden distinguir dos variantes diferentes dependiendo de cómo se extraen los vecinos para una nueva instancia  $i$ . La variante *enRango* considera los ejemplos  $k$  más cercanos  $x_j$  con sus etiquetas de clase  $y_j$  en el rango  $[y_{min}, y_{max}]$ . La

versión *fueraDeRango* extrae los vecinos, independientemente de su clases, y luego, se eliminan aquellos cuyas clases están fuera del rango  $r_i$ . Como en el  $k$ -NN estándar, la clase mayoritaria entre los vecinos de  $k$  se usa como la etiqueta predicha.

MkNN requiere conjuntos de datos monotónicos para funcionar correctamente. Por ello, se utiliza una técnica de retiquetado para transformar los datos de entrenamiento. Estas técnicas pretenden identificar las violaciones de la monotonicidad y hacer los mínimos cambios posibles con la mínima diferencia de clase para eliminarlas [4].

### II-C. $k$ -Vecinos más Cercanos Difuso

Los métodos difusos de los  $k$ -Vecinos más Cercanos [8] incluyen conceptos difusos en la clásica regla  $k$ -NN para aprender de conjuntos difusos y producir reglas de clasificación difusas. Para una nueva instancia  $x_i$ , el algoritmo original FkNN [7] extrae sus  $K$  vecinos más cercanos de la misma manera que el  $k$ -NN estándar. Sin embargo, sus pertenencias a cada clase  $l$  se calculan con la siguiente expresión:

$$u(x, l) = \frac{\sum_{j=1}^K u(x_j, l) * \frac{1}{\|x - x_j\|^{(m-1)}}}{\sum_{j=1}^K \frac{1}{\|x - x_j\|^{(m-1)}}} \quad (2)$$

Como se muestra en 2, la pertenencia  $u(x_i, l) = u_{il}$  de la muestra  $x_i$  a la clase  $l$  se asigna con el producto de la pertenencia a la clase  $u(x_j, l)$  de los vecinos  $x_j$  y la inversa de sus distancias a  $x_i$ . Este último sirve como un peso que sesga hacia las pertenencias de las muestras más cercanas. El parámetro  $m$  determina el grado de influencia de las distancias a los vecinos. La etiqueta final de clase para el ejemplo  $x_i$  será aquella  $l$  con el mayor grado de pertenencia  $u_{il}$ .

Partiendo de un conjunto de entrenamiento etiquetado, FkNN [7] lo transforma en un conjunto difuso con pertenencias de clase usando la regla del vecino más cercano. Para cada muestra de entrenamiento  $x$ , se extraen sus  $k$  vecinos más cercanos y, luego, sus pertenencias se calculan de acuerdo a 3. Esta transformación ha demostrado ser útil frente a muestras ruidosas, ya que sus pertenencias se repartirán por las clases circundantes perdiendo su influencia.

$$u(x, l) = \begin{cases} 0,51 + 0,49 * (nn_l/k) & \text{if } l = C(x) \\ 0,49 * (nn_l/k) & \end{cases} \quad (3)$$

## III. $k$ -VECINOS MÁS CERCANOS DIFUSO PARA CLASIFICACIÓN MONOTÓNICA

En esta sección, se explica en detalle nuestra propuesta de  $k$ -Vecinos más Cercanos Difuso para clasificación monotónica.

### III-A. De probabilidades a etiqueta final de clase

Es esencial elegir el mecanismo ideal según la monotonicidad para obtener una clase final a partir de una función de probabilidad. La clase más probable es el método más



común. Sin embargo, esto podría ser inapropiado para escenarios con restricciones monótonas. Por ejemplo, sea  $x \leq y$  y sus probabilidades  $f_x = (0,2,0,2,0,4,0,2,0,0)$  y  $f_y = (0,0,0,4,0,3,0,2,0,1)$ , entonces sus clases finales rompen la monotonía:  $\text{argmax}(f_x) = l_3 > l_2 = \text{argmax}(f_y)$ . Aunque, la instancia  $y$  tenga mayor peso en etiquetas más altas que  $x$ . Es más,  $f_y$  domina débilmente a  $f_x$  según el primer grado de dominancia estocástica (FSD) [10], ya que la función de distribución acumulativa  $F_x$  de  $x$ , es mayor, elemento por elemento, que  $F_y$ , es decir,  $f_x \preceq_{FSD} f_y \iff (\forall l \in \mathcal{Y})(F_x(l) \geq F_y(l))$ . La FSD ha sido de utilidad para definir las restricciones de monotonía en las clasificaciones estocásticas [5], [11], con la expresión  $x \leq y \implies f_x \preceq_{FSD} f_y$ .

La mediana satisface dicha expresión, preservando la monotonía [5], [10]. Esta se calcula siguiendo la definición de percentil 50 como el rango  $[l_m, l_M]$ :

$$\begin{aligned} l_m &= \min\{l \in \mathcal{Y} | \text{Prob}\{X \leq l\} \geq 1/2\} \\ l_M &= \max\{l \in \mathcal{Y} | \text{Prob}\{X \geq l\} \geq 1/2\} \end{aligned} \quad (4)$$

Volviendo al ejemplo anterior, las clases para  $x$  y  $y$  elegidas por la mediana no rompen la monotonía:  $\text{med}(f_x) = \text{med}(f_y) = 3$ .

### III-B. Pertenencias de clase robustas al ruido monótono

En esta subsección, se explica el cálculo de pertenencias de clase rediseñado para reducir la influencia de las instancias no-monótonas. En primer lugar, se ha de tratar las violaciones monótonas más simples, es decir, instancias repetidas con diferentes clases. MonFkNN primero sustituye las réplicas de cualquier ejemplo  $x$  por solo vector de característica  $x$  y sus pertenencias  $u(x)$ . La probabilidad  $u(x, l)$  de la instancia  $x$  y la clase  $l$  se calcula con frecuencia de ejemplos duplicados pertenecientes a  $l$ , como se muestra en la siguiente expresión:

$$u(x, l) = \frac{|\{z \in \mathcal{D} | z = x \wedge C(z) = l\}|}{|\{z \in \mathcal{D} | z = x\}|} \quad (5)$$

Posteriormente, MonFkNN estima las pertenencias del resto de instancias con la información de los vecinos más cercanos a cada una. Sin embargo, estos vecinos son extraídos con un MkNN configurado como *enRango* en lugar de uno tradicional. Una vez obtenidos los vecinos de cada ejemplo  $x$ , la información de clase se fusiona en pertenencias de  $x$ . La probabilidad  $u(x, l)$  de pertenecer a la clase  $l$  se calcula con la siguiente expresión:

$$u(x, l) = \begin{cases} RCr + (nn_l/k) * (1 - RCr) & \text{if } l = C(x) \\ (nn_l/k) * (1 - RCr) & \end{cases} \quad (6)$$

donde  $nn_l$  es el número de vecinos de la clase  $l$ ,  $k$  el número total de vecinos y  $C(x)$  es la etiqueta original del ejemplo  $x$ .  $RCr$  es un nuevo parámetro llamado *Relevancia de la clase real*.  $RCr$  puede ser visto como la probabilidad mínima asignada a la clase original  $C(x)$  de la instancia  $x$ , en caso de que no haya vecinos etiquetados con  $C(x)$ .

Hay algunos valores para  $RCr$  en el rango  $[0, 1]$  que tienen comportamientos muy interesantes y distintos. En el caso de un conjunto de datos realmente ruidoso,  $RCr$  podría establecerse en 0, dejando toda la responsabilidad al cálculo del rango  $r_i$  de las clases válidas y los vecinos más cercanos. En presencia de solo instancias repetidas, el usuario puede optar por tratarlas con  $RCr = 1$ . Finalmente, si se desea considerar las instancias etiquetadas originalmente, se recomienda asignar  $RCr$  a 0,5. Este valor asegura que la clase real esté dentro del conjunto de medianas. En contraste con FkNN y sus 0,51, si todos los vecinos pertenecen a la misma clase diferente a la actual, nuestro método obliga a elegir una clase intermedia. Por lo general, este último valor ofrece un comportamiento balanceado, estable y con un mejor rendimiento.

### III-C. Agregación flexible de las pertenencias

Después de estimar la pertenencia de clase de cada instancia de entrenamiento, nuestro algoritmo está listo para predecir nuevos ejemplos. Esta fase de predicción ha sido diseñada con una mayor flexibilidad, permitiendo al usuario elegir entre predicciones más precisas o puramente monótonas.

Para ello, nuestro método utiliza otro MkNN para obtener los vecinos a utilizar en la predicción final. Este MkNN tiene también dos versiones, *enRango* y *fueraDeRange*. Pero son sustancialmente diferentes en comparación con las variantes originales, especialmente para la variante *fueraDeRange*.

La alternativa *enRango* se basa en la misma idea del MkNN original, donde los vecinos de un ejemplo deben pertenecer a un conjunto de clases monótonicamente válidas. Sin embargo, este rango de clases se obtiene utilizando las medianas adquiridas de las pertenencias de clase de las instancias de entrenamiento. Este avance mejora nuestro método hacia la robustez del ruido monótono. La primera fase de MkNN se centra en la preservación de la monotonía de las medianas resultantes, para servir como una ventaja para las predicciones finales.

La versión *fueraDeRange* de nuestro método es completamente diferente de la anterior regla *fueraDeRange*. Ha sido diseñada con la intención de priorizar la precisión del clasificador sobre la monotonía. Con este propósito, nuestro método considera cualquier ejemplo como un vecino válido sin importar su clase. A diferencia del modelo original, no se realiza ningún filtrado o eliminación de vecinos fuera del rango válido. Sin embargo, su relevancia en la agregación de pertenencias se puede reducir, gracias a un factor de penalización introducido en la expresión de agregación.

Luego, para un nuevo ejemplo  $x$ , se obtienen sus vecinos más cercanos según la variante elegida. Sus pertenencias se agregan con la misma fórmula utilizada por el FkNN original con la adición del factor de penalización para la versión *fueraDeRange*. La siguiente expresión muestra cómo se integra este parámetro:

$$u(x, l) = \frac{\sum_{j=1}^K u(x_j, l) * \frac{pOR_j}{\|x - x_j\|^{(m-1)}}}{\sum_{j=1}^K \frac{pOR_j}{\|x - x_j\|^{(m-1)}}} \quad (7)$$

Como anteriormente, la pertenencia  $u(x_i, l)$  de la nueva muestra  $x_i$  a la clase  $l$  es el resultado de la suma de las pertenencias a dicha clase  $u(x_j, l)$  de los vecinos  $x_j$  ponderadas inversamente con la distancia a  $x_i$ . En la versión *fueraDeRange* de nuestro método, hay otro factor de ponderación en la contribución a las probabilidades finales, el parámetro mencionado como "penalización de fueraDeRango" ( $pOR$ ). El factor  $pOR_j$  sólo se aplica si la clase  $y_j$  del vecino  $x_j$  no se encuentra en el rango de clases válidas  $r_i$  de  $x_i$ . Se puede configurar con valores continuos de 0 a 1. Cuando se asigna a 1, no se aplica ninguna penalización. El valor 0 significa una penalización completa, es decir, los vecinos con clases inválidas no participarán en la agregación. Este último comportamiento es equivalente a la variante *fueraDeRango* del  $MkNN$  original. Se recomienda el uso de 0.5, ya que es un buen equilibrio entre reducir su relevancia y considerarlos en la decisión.

Finalmente, la predicción de clase del nuevo ejemplo  $x$  es la mediana de las pertenencias de clase normalizadas resultantes.

MonFkNN se ha desarrollado para ser robusto al ruido monótono y versátil en múltiples escenarios gracias a sus parámetros. Entre sus posibilidades, destacan dos configuraciones con un comportamiento muy distintivo: Monótono Puro (PM) y Monótono Aproximado (AM). La configuración monótona pura corresponde a un valor de 0.5 para el parámetro  $RCr$  y el uso de la regla *enRango* para obtener las pertenencias de nuevas instancias. Este enfoque pretende dar predicciones con las mínimas violaciones de la monotonidad.

La configuración monótona aproximada prioriza la capacidad de predicción y relaja las restricciones monótonas. Las pertenencias del entrenamiento se obtienen mediante el tratamiento de las muestras repetidas. Los ejemplos únicos tendrán una probabilidad de 1 para la clase real y 0 para el resto. Este comportamiento se consigue con  $RCr = 1$ . Ya que buscamos predicciones más precisas, se consideran todas las instancias como vecinos válidos. Sin embargo, aquellas con etiquetas de clase inválidas contribuirán con la mitad de sus probabilidades ( $pOR = 0,5$ ).

#### IV. METODOLOGÍA EXPERIMENTAL

Esta sección introduce el marco experimental utilizado en los diferentes estudios empíricos del trabajo. En dichos experimentos, se han incluido 12 conjuntos de datos diferentes. Estos son retratados en la Tabla I, donde se detallan el número de instancias, atributos y clases de cada conjunto en las columnas Ins., At. y Cl., respectivamente. La columna Direcciones indica la dirección de la relación monótona entre cada atributo y la clase: monotonía directa (+) o inversa (-).

Se ha llevado a cabo un esquema de validación cruzada de 10 particiones (10-fcv) para ejecutar los diferentes clasificadores sobre estos conjuntos. Sus particiones han sido extraídas del repositorio KEEL [12].

Tabla I: Descripción de los 12 conjunto de datos usados.

Conjuntos	Ins.	At.	Cl.	Direcciones
<i>artiset</i>	1000	2	10	directas
<i>balance</i>	625	4	3	{-, -, +, +}
<i>bostonhousing4cl</i>	506	13	4	{-, +, -, +, -, +, -, -, -, +, -, -}
<i>car</i>	1728	6	4	directas
<i>ERA</i>	1000	4	9	directas
<i>ESL</i>	488	4	9	directas
<i>LEV</i>	1000	4	5	directas
<i>machineCPU</i>	209	6	4	{-, +, +, +, +, +}
<i>qualitative_bankruptcy</i>	250	6	2	directas
<i>SWD</i>	1000	10	4	directas
<i>windsorhousing</i>	546	11	2	directas
<i>wisconsin</i>	683	9	2	directas

La tabla II muestra los clasificadores involucrados en la comparación experimental y sus parámetros.

Tabla II: Parámetros considerados para los algoritmos a comparar.

Algoritmos	Parámetros
MkNN [4] OSDL [5]	$k = 5$ , distancia = euclidiana, tipoVecinos = enRango equilibrado = No, tipoClasificación = mediana, límiteInferior = 0, límiteSuperior = 1, ajusteInterpolación = No, ponderado = No, pasoInterpolación = 10, gradoInterpolación = 0.5, resolución = conservativa
OLM [6]	tipoClasificación = conservativa
MID [3]	$R = 1$ , confianza = 0.25, elementosPorHoja = 2
Mon FuzzykNN	$k = 5$ , $K = 9$ , distancia = euclidiana
Monótono Puro	$RCr = 0.5$ , tipoVecinos = enRango
Monótono Aprox.	$RCr = 1$ , tipoVecinos = fueraDeRango, $pOR = 0,5$

Para evaluar la competencia de los clasificadores, se han empleado tres medidas que cubren diferentes aspectos de su rendimiento: capacidad predictiva con la precisión estándar, coste de los errores con el error absoluto medio (MAE) y monotonidad con el Índice No Monótono (NMI). El NMI mide la proporción de pares de muestras que rompen la monotonidad respecto al total de pares.

#### V. RESULTADOS Y ANÁLISIS

Esta sección presenta los resultados de diferentes estudios empíricos y sus análisis.

##### V-A. Evaluación de las propuestas de $k$ -Vecinos más Cercanos Difuso Monótono

A continuación, una comparación entre las versiones Pura y Aproximada de MonFkNN, destacando los diferentes comportamientos y aspectos de su rendimiento. La Tabla III contienen los resultados de las dos configuraciones de la propuesta en términos de Precisión, MAE y NMI. La fuente en negrita indica los mejores resultados obtenidos para cada conjunto de datos y métrica.

En la Tabla III, las diferencias entre ambos enfoques quedan claramente patentes. Tal como fueron diseñados, MonFkNN Aproximado (AM) tiene una mejor precisión en promedio en



Tabla III: Resultados de las versiones Puramente y Cuasi Monótonicas de MonFkNN.

	Precisión		MAE		NMI	
	PM ( $RCr = 0, 5$ )	AM ( $pOR = 0, 5$ )	PM ( $RCr = 0, 5$ )	AM ( $pOR = 0, 5$ )	PM ( $RCr = 0, 5$ )	AM ( $pOR = 0, 5$ )
<i>artiset</i>	0,9309	<b>0,9349</b>	0,0691	<b>0,0651</b>	<b>0,0000</b>	<b>0,0000</b>
<i>balance</i>	<b>0,9307</b>	0,9008	<b>0,0853</b>	0,1168	<b>0,0000</b>	0,0001
<i>bostonhousing4cl</i>	0,6561	<b>0,7134</b>	0,3972	<b>0,3261</b>	<b>0,0000</b>	0,0001
<i>car</i>	0,9740	<b>0,9834</b>	0,0295	<b>0,0195</b>	<b>0,0000</b>	<b>0,0000</b>
<i>ERA</i>	0,2420	<b>0,2430</b>	<b>1,2813</b>	1,2993	<b>0,0052</b>	<b>0,0052</b>
<i>ESL</i>	0,7036	<b>0,7131</b>	0,3149	<b>0,3053</b>	0,0004	<b>0,0003</b>
<i>LEV</i>	<b>0,6377</b>	0,6110	<b>0,3927</b>	0,4223	<b>0,0004</b>	0,0009
<i>machineCPU</i>	<b>0,7033</b>	0,6699	<b>0,3158</b>	0,3493	<b>0,0002</b>	0,0017
<i>qualitative_bankruptcy</i>	<b>0,9960</b>	<b>0,9960</b>	<b>0,0040</b>	<b>0,0040</b>	<b>0,0000</b>	<b>0,0000</b>
<i>SWD</i>	0,5807	<b>0,5833</b>	<b>0,4370</b>	0,4380	0,0007	<b>0,0003</b>
<i>windsorhousing</i>	0,7576	<b>0,7839</b>	0,2424	<b>0,2161</b>	<b>0,0005</b>	0,0051
<i>wisconsin</i>	0,9653	<b>0,9663</b>	0,0347	<b>0,0337</b>	<b>0,0000</b>	<b>0,0000</b>
<i>Media:</i>	0,7565	<b>0,7583</b>	0,3003	<b>0,2996</b>	<b>0,0006</b>	0,0012

el 75 % de los conjuntos utilizados. Por otro lado, MonFkNN Puro (PM) logra predicciones monótonicamente más confiables en 10 de los 12 conjuntos de datos utilizados, con grandes diferencias en los problemas de *Windsorhousing* y *MachineCPU*. Ambos tienen un resultado estable y bueno en términos de MAE, siendo la versión AM un poco mejor.

Ya que la monotonidad se priorizada la mayoría de las veces en la clasificación con restricciones monótonicas, usaremos la variante Pura de MonFkNN en los siguientes estudios empíricos.

#### V-B. Comparación con el Estado-del-Arte

A lo largo de este experimento, se evalúa el rendimiento de MonFkNN en comparación a los clasificadores monótonicos del Estado-del-Arte. En esta, se busca un equilibrio entre predicciones precisas y monótonicas.

La Tabla IV recoge los resultados de precisión para los diferentes conjuntos de datos obtenidos por los algoritmos probados. En términos de precisión, MonFkNN rinde bastante mejor con un amplio margen. Nuestro método logra predicciones más precisas para 7 conjuntos de datos, con casos particularmente notables, como *balance* o *ESL*.

Tabla IV: Resultados en precisión obtenidos por los algoritmos evaluados.

	MonFkNN-PM	MkNN	OSDL	OLM	MID
<i>artiset</i>	<b>0,9309</b>	0,9199	0,1952	0,7948	0,7237
<i>balance</i>	<b>0,9307</b>	0,8624	0,6352	0,8320	0,7808
<i>bostonhousing4cl</i>	0,6561	0,6126	0,2787	0,5277	<b>0,6739</b>
<i>car</i>	<b>0,9740</b>	0,9711	0,9549	0,9543	0,8027
<i>ERA</i>	0,2420	0,1990	0,2320	0,1690	<b>0,2760</b>
<i>ESL</i>	<b>0,7036</b>	0,6332	0,6721	0,5738	0,6414
<i>LEV</i>	0,6377	0,4630	<b>0,6400</b>	0,4250	0,6070
<i>machineCPU</i>	<b>0,7033</b>	0,6890	0,2919	0,6746	0,6220
<i>qualitative_bankruptcy</i>	<b>0,9960</b>	<b>0,9960</b>	0,9160	0,9800	0,9840
<i>SWD</i>	0,5807	0,5200	<b>0,5840</b>	0,4160	0,5540
<i>windsorhousing</i>	0,7576	0,5861	0,4927	0,7564	<b>0,8205</b>
<i>wisconsin</i>	<b>0,9653</b>	0,9649	0,9590	0,8873	0,9517
<i>Media:</i>	<b>0,7565</b>	0,7014	0,5710	0,6659	0,7031

En la clasificación con restricciones monótonicas, el coste de los errores puede ser esencial. La Tabla V muestra el error en forma de MAE cometido por cada clasificador. Al igual que el rendimiento de precisión, MonFkNN es claramente mejor

que el resto con el error más pequeño en promedio y para 8 de los conjuntos de datos. En aquellos problemas donde otros son superiores, como *LEV* o *wisconsin*, este consigue resultados realmente cercanos.

Tabla V: Resultados en MAE obtenidos por los algoritmos evaluados.

	MonFkNN-PM	MkNN	OSDL	OLM	MID
<i>artiset</i>	<b>0,0691</b>	0,0771	1,6897	0,2082	0,3123
<i>balance</i>	<b>0,0853</b>	0,1504	0,4912	0,1920	0,3360
<i>bostonhousing4cl</i>	0,3972	0,4901	0,9368	0,5988	<b>0,3893</b>
<i>car</i>	<b>0,0295</b>	0,0359	0,0475	0,0538	0,2506
<i>ERA</i>	<b>1,2813</b>	1,4270	1,2850	2,1500	1,2970
<i>ESL</i>	<b>0,3149</b>	0,3791	0,3607	0,4734	0,3934
<i>LEV</i>	0,3927	0,5740	<b>0,3920</b>	0,6680	0,4290
<i>machineCPU</i>	<b>0,3158</b>	0,3301	0,9043	0,3589	0,4211
<i>qualitative_bankruptcy</i>	<b>0,0040</b>	<b>0,0040</b>	0,0840	0,0200	0,0160
<i>SWD</i>	<b>0,4370</b>	0,4840	<b>0,4370</b>	0,7630	0,4750
<i>windsorhousing</i>	0,2424	0,4304	0,5073	0,2436	<b>0,1795</b>
<i>wisconsin</i>	0,0347	<b>0,0337</b>	0,0410	0,1127	0,0483
<i>Media:</i>	<b>0,3003</b>	0,3680	0,5980	0,4869	0,3790

En relación a la monotonidad, la Tabla VI presenta los resultados de los NMI alcanzados. En este caso, la competencia por ser el mejor está mucho más reñida. OLM y MID obtienen predicciones claramente menos monótonas. Este último tiene el peor comportamiento considerando sólo la monotonidad. MonFkNN, MkNN y OSDL funcionan de manera similar. MonFkNN y OSDL son ligeramente mejores en promedio.

Tabla VI: Resultados en NMI obtenidos por los algoritmos evaluados.

	MonFkNN-PM	MkNN	OSDL	OLM	MID
<i>artiset</i>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	0,0039
<i>balance</i>	<b>0,0000</b>	0,0001	0,0006	<b>0,0000</b>	0,0017
<i>bostonhousing4cl</i>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	0,0003	0,0022
<i>car</i>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	0,0046
<i>ERA</i>	0,0052	0,0056	<b>0,0049</b>	0,0063	0,0082
<i>ESL</i>	<b>0,0004</b>	0,0012	0,0006	0,0025	0,0021
<i>LEV</i>	<b>0,0004</b>	0,0010	<b>0,0004</b>	0,0043	0,0018
<i>machineCPU</i>	0,0002	<b>0,0000</b>	<b>0,0000</b>	0,0014	0,0037
<i>qualitative_bankruptcy</i>	<b>0,0000</b>	<b>0,0000</b>	0,0003	<b>0,0000</b>	0,0002
<i>SWD</i>	0,0007	<b>0,0005</b>	0,0009	0,0015	0,0020
<i>windsorhousing</i>	0,0005	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	0,0030
<i>wisconsin</i>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>	<b>0,0000</b>
<i>Media:</i>	<b>0,0006</b>	0,0007	<b>0,0006</b>	0,0014	0,0028

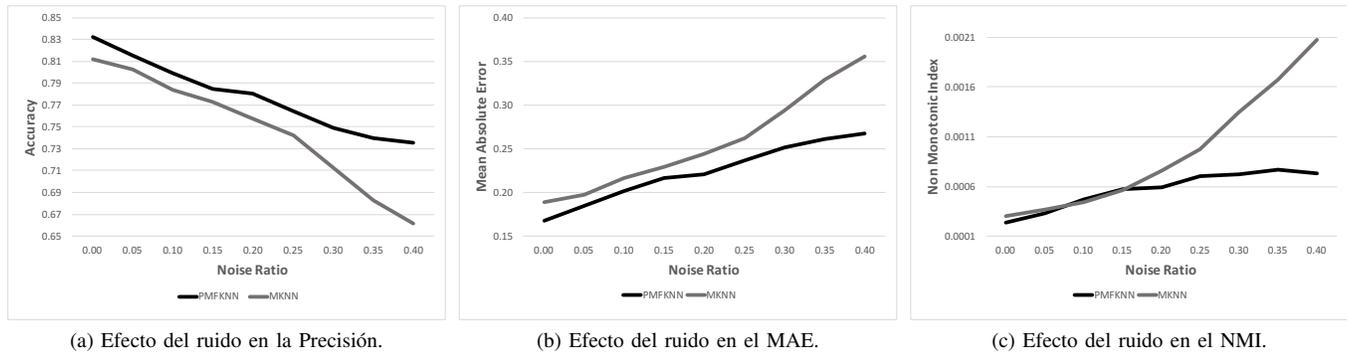


Figura 1: Rendimiento de Puro MonFkNN y MkNN con los diferentes conjuntos ruidos de Artiset.

### V-C. Sobre la robustez al ruido monótono de $k$ -Vecinos más Cercanos Difuso Monótono

Con este último estudio empírico, pretendemos probar la robustez de MonFkNN frente a la presencia de violaciones monótonas o ruido en los sets de entrenamiento en contraste con MkNN. Para ello, se ha introducido diferentes cantidades de instancias ruidosas en las particiones de entrenamiento del conjunto de datos artificial Artiset. Luego, se han comparado el comportamiento de MonFkNN y MkNN en términos de precisión, MAE y NMI, mientras que el ratio de ruido aumenta.

La figura 1 muestra el comportamiento de MonFkNN y MkNN (líneas más oscuras y más claras, respectivamente) en base a la precisión (1a), MAE (1b) y NMI (1c), con la progresión del ruido. Como era de esperar, mientras la cantidad de ruido aumenta, el rendimiento de ambos métodos empeora. Sin embargo, hay alguna gran diferencia entre ambos clasificadores.

En primer lugar, el comportamiento de cara al ruido de MonFkNN es claramente mejor que el del MkNN en todos los aspectos probados. Las líneas negras siempre están sobre las más claras de la figura 1a, lo que indica siempre una precisión mayor, y debajo de ellas en las figuras 1b y 1c, lo que significa mejores MAE y NMI para MonFkNN. Por lo general, la distancia entre ambos métodos es amplia, con excepción de los resultados de NMI obtenidos para los valores más pequeños de ruido. Además, mientras que el índice de ruido aumenta, sus diferencias también aumentan.

Con estos experimentos, MonFk-NN ha demostrado una fuerte robustez al ruido monótono preservando su buen rendimiento en términos de precisión, costes de error y monotonicidad.

## VI. CONCLUSIONES

En este trabajo, se ha propuesto un modelo difuso de  $k$ -Vecinos más Cercanos para la clasificación con restricciones monótonas. La transferencia de una función de probabilidades a una clase final se ha adaptado para que respete dichas restricciones. Se ha diseñado mecanismos para reducir la influencia de las violaciones monótonas. Como demostración

de su flexibilidad, se han presentados dos configuraciones diferentes del modelo con comportamientos muy distintos.

Durante el análisis experimental, se ha mostrado el gran potencial en relación a la monotonicidad de la configuración puramente monótona y la buena precisión de la versión aproximada de MonFkNN. En comparación con otros métodos, MonFkNN es significativamente mejor en términos de precisión y coste de error, igualando los mejores resultados de NMI. Además, ha demostrado una fuerte robustez a grandes cantidades de ruido preservando su buen rendimiento.

## REFERENCIAS

- [1] C.-C. Chen and S.-T. Li, "Credit rating with a monotonicity-constrained support vector machine model," *Expert Systems with Applications*, vol. 41, no. 16, pp. 7235–7247, 2014.
- [2] J.-R. Cano, N. R. Aljohani, R. A. Abbasi, J. S. Alowidbi, and S. Garcia, "Prototype selection to improve monotonic nearest neighbor," *Engineering Applications of Artificial Intelligence*, vol. 60, pp. 128–135, 2017.
- [3] A. Ben-David, "Monotonicity maintenance in information-theoretic machine learning algorithms," *Machine Learning*, vol. 19, no. 1, pp. 29–43, 1995.
- [4] W. Duivesteyn and A. Feelders, "Nearest neighbour classification with monotonicity constraints," in *ECML/PKDD (1)*, 2008, pp. 301–316.
- [5] S. Lievens, B. De Baets, and K. Cao-Van, "A probabilistic framework for the design of instance-based supervised ranking algorithms in an ordinal setting," *Annals of Operations Research*, vol. 163, no. 1, pp. 115–142, 2008.
- [6] A. Ben-David, "Automatic generation of symbolic multiattribute ordinal knowledge-based dsss: methodology and applications," *Decision Sciences*, vol. 23, pp. 1357–1372, 1992.
- [7] J. M. Keller, M. R. Gray, and J. A. Givens, "A fuzzy  $k$ -nearest neighbor algorithm," *IEEE transactions on systems, man, and cybernetics*, no. 4, pp. 580–585, 1985.
- [8] J. Derrac, S. García, and F. Herrera, "Fuzzy nearest neighbor algorithms: Taxonomy, experimental analysis and prospects," *Information Sciences*, vol. 260, pp. 98–119, 2014.
- [9] W. Kotłowski and R. Słowiński, "On nonparametric ordinal classification with monotonicity constraints," *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, no. 11, pp. 2576–2589, 2013.
- [10] H. Levy, *Stochastic dominance: Investment decision making under uncertainty*. Springer, 2015.
- [11] S. Lievens and B. De Baets, "Supervised ranking in the weka environment," *Information Sciences*, vol. 180, no. 24, pp. 4763–4771, 2010.
- [12] I. Triguero, S. González, J. M. Moyano, S. García, J. Alcalá-Fdez, J. Luengo, A. Fernández, M. J. del Jesús, L. Sánchez, and F. Herrera, "Keel 3.0: an open source software for multi-stage analysis in data mining," *International Journal of Computational Intelligence Systems*, vol. 10, no. 1, pp. 1238–1249, 2017.



# Eventos raros, anomalías y novedades vistas desde el paraguas de la clasificación supervisada

Ander Carreño  
Intelligent Systems Group (ISG)  
UPV/EHU  
P. Manuel Lardizabal 1  
20018 San Sebastián (Spain)  
Email: ander.carreno@ehu.eus

Iñaki Inza  
Intelligent Systems Group (ISG)  
UPV/EHU  
P. Manuel Lardizabal 1  
20018 San Sebastián (Spain)  
Email: inaki.inza@ehu.eus

Jose A. Lozano  
Intelligent Systems Group (ISG)  
UPV/EHU, 28018 San Sebastián (Spain)  
Baque Center For Applied Mathematics  
BCAM, 48009 Bilbao (Spain)  
Email: ja.lozano@ehu.eus

**Resumen**—En los últimos años, muchas áreas han contribuido a resolver problemas denominados: eventos raros (*rare events*), anomalías (*anomalies*), novedades (*novelties*) y datos atípicos (*outliers*). Estas áreas han creado una mezcla entre términos y problemas. Por un lado, problemas similares han sido descritos con diferentes términos. Por el otro, el mismo término ha sido utilizado para describir problemas diferentes. Dada esta confusión, este artículo tiene como objetivo poner orden en el área viendo todos estos problemas desde el prisma de la clasificación supervisada. En concreto, se asocia a cada término un escenario de clasificación, se muestran ejemplos, y se consideran aquellas características asociadas a cada término que comparten la mayoría de artículos de la literatura. Por lo tanto, los escenarios se formalizan desde el punto de vista de la clasificación supervisada, se revisan los objetivos de la tarea de clasificación, las métricas usadas para evaluar el rendimiento, las características de los datos de entrada y las técnicas utilizadas en cada uno de ellos.

**Index Terms**—Eventos raros, anomalías, novedades, datos atípicos, outliers, aprendizaje automático, clasificación supervisada, aprendizaje desbalanceado.

## I. INTRODUCCIÓN

Una gran cantidad de aplicaciones requieren filtrar o detectar observaciones anormales en los datos. En algunas situaciones, las anomalías son descritas como eventos raros, anomalías, novedades, outliers, excepciones, aberraciones, sorpresas, peculiaridades, ruido o contaminantes entre otras. De todas estas acepciones, las más comunes son: eventos raros, anomalías, novedades y outliers. La importancia de detectar estas anomalías es debido a que estas pueden estar relacionadas con situaciones críticas o interesantes en una gran cantidad de dominios. Por ejemplo, en seguridad, las intrusiones son consideradas anomalías [1]–[3]; en seguridad vial, los accidentes de tráfico son considerados anomalías [4]; en geología la erupción de un volcán es una anomalía [5]; en el control de alimentos, cuerpos extraños dentro de envoltorios son también anomalías [6]; o en el caso de la neurociencia, un estímulo que no se ha experimentado anteriormente es también una anomalía [7].

Considerando la importancia de las anomalías, se ha desarrollado una larga lista de trabajos relacionados con estos términos. Sin embargo, se ha formado una mezcla entre los términos y los problemas. En primer lugar, se han utilizado

diferentes términos para describir el mismo problema. Por ejemplo, en [8], los autores tratan un problema en el que predicen si se va a producir un desprendimiento en una zona concreta y en un periodo de tiempo acotado. Para ello, crean un mapa de zonas susceptibles a que ocurra un desprendimiento. Cada zona tiene asociado un riesgo de desprendimiento. Este riesgo se predice con un modelo aprendido con datos sobre zonas donde ha ocurrido un desprendimiento y zonas en las que no. Es decir, el modelo se aprende con datos etiquetados en dos categorías: desprendimiento y no desprendimiento. Estos desprendimientos de tierra son descritos como *eventos raros*, denotando que son eventos que ocurren pocas veces. No obstante, en [1], se trata un problema similar desde el punto de vista de la clasificación supervisada, pero que se describe con otro término. En éste, se realiza un estudio en la industria ferroviaria. Las puertas de pasajeros cuentan con diferentes sistemas para abrir y cerrar las puertas de los trenes, que aseguran el confort y la seguridad de los pasajeros abordo. En algunas situaciones, por el deterioro de estos sistemas, el sistema de apertura y cierre de las puertas falla. Por lo tanto, la tarea de predicción se enfoca en predecir si la puerta va a fallar en un periodo de tiempo acotado. Para ello, se aprende un modelo con datos etiquetados en dos categorías: fallos (puertas que fallan) y situaciones normales. En este estudio, los errores en las puertas se denominan *anomalías*, denotando también situaciones que ocurren pocas veces. Como se puede ver, los dos problemas son prácticamente idénticos desde el punto de vista de la clasificación supervisada, pero se han utilizado diferentes términos para describir las anomalías. Por lo tanto, analizando los problemas desde el punto de vista de la clasificación supervisada, ambos problemas se pueden modelar como problemas de clasificación binarios con distribuciones de probabilidad desbalanceadas en las clases.

Por otro lado, también el mismo término ha sido utilizado para describir problemas diferentes. En los siguientes dos problemas, los autores utilizan el término *novedad*, *novelty* en inglés, para describir las anomalías. En [3], detectan si un paciente está sufriendo un ataque epiléptico. Dada la fuerza de las convulsiones que sufren estos pacientes durante un ataque, pueden hacerse daño a ellos mismos. En consecuencia, detectar estos ataques lo más rápido posible es muy importante

para evitar los daños. Por lo tanto, el objetivo de este estudio es detectar si un paciente está sufriendo un ataque epiléptico. Para ello, se aprende un modelo predictivo con datos de movimientos de pacientes recogidos con un acelerómetro 3D. Estos datos previamente han sido grabados durante varios días en los cuales, en algún momento, los pacientes han sufrido una o varias convulsiones. Después, estos datos son segmentados en ventanas de tiempo fijas y, estas particiones son etiquetadas como ataque (porque ha sufrido un ataque en este tramo temporal) o como normal. Por lo tanto, cuando llega un nuevo caso, es decir, al recibir los datos de un paciente que está constantemente monitorizado, el clasificador detecta si está o no sufriendo un ataque epiléptico (i.e. identificado como novedad). Sin embargo en [6], se detectan cuerpos extraños dentro de contenedores de alimentos. En algunas ocasiones, ciertos cuerpos extraños como insectos, piedras o plásticos son encontrados dentro de los envoltorios de alimentos, tales como bandejas o tetrabriks. Detectar estos cuerpos extraños es muy importante para la imagen de las empresas productoras de este tipo de productos y para los consumidores finales. Por lo tanto, partiendo únicamente de imágenes de rayos X de alimentos limpios de cuerpos extraños, es decir, desde nuestro prisma, de una única clase, se aprende un modelo que es capaz de detectar estos cuerpos extraños, que son descritos como novedades en este estudio. Como se puede apreciar en ambos ejemplos, el mismo término (novedad) ha sido utilizado para describir las anomalías. No obstante, ambos trabajos no se basan en el mismo escenario de aprendizaje, y en [3] el modelo predictivo es aprendido con tanto instancias normales como anormales mientras que en [6] únicamente se aprende el modelo con datos normales (sin cuerpos extraños).

Sin embargo, no sólo los problemas descritos anteriormente, sino la mayoría de los problemas reseñados con los términos eventos raros, anomalías y novedades, se pueden formalizar como problemas de clasificación supervisada. Por lo tanto, este artículo trata de poner orden en esta mezcla y confusión de términos y problemas, asignando un único escenario de aprendizaje a cada uno de los términos, que viene a ser el más compartido en la literatura. Después, describe cada uno de los escenarios de clasificación mediante la asignación de aquellas características que más comparten los problemas de la literatura asociados a cada término.

El artículo se organiza de la siguiente manera. Cada sección corresponde a un escenario de clasificación, siendo: la Sección II para la detección de eventos raros, la Sección III para la detección de anomalías y la Sección IV para las novedades. En la Sección V se discute sobre el término outlier y, finalmente, en la Sección VI se exponen las conclusiones del artículo.

## II. DETECCIÓN DE EVENTOS RAROS

La mayoría de los artículos que utilizan el término evento raro para describir las anomalías tienen la dimensión temporal como una característica clave. Por ejemplo en [4], se trata un problema relacionado con la seguridad vial en la autopista Attica (Grecia). Los autores dividen la autopista en diferentes secciones en las que quieren detectar si ha ocurrido

un accidente en la última hora. Para ello, crean un modelo basándose en información histórica tanto de sensores terrestres como de cámaras de tráfico en el que conocen si ha ocurrido un accidente en las diferentes secciones y en intervalos de 1 hora. Por lo tanto, llegada una nueva información de 1 hora en una sección, el clasificador predice la existencia de un accidente. Otra aplicación relacionada con el término evento raro, es [5]. En este artículo se realiza un estudio sobre la erupción de dos volcanes de Sudamérica. Los autores quieren detectar si estos volcanes van a entrar en erupción en una ventana de tiempo acotada. Para ello, aprenden un modelo con datos históricos de actividad volcánica en el que eventualmente hay erupciones. Esta estimación la realizan mediante un proceso de Poisson en el que se predice si va a haber o no una erupción en un horizonte acotado. Otro ejemplo diferente relacionado es [9]. En este artículo se realiza un estudio sobre la probabilidad de fallo en cascada de una red eléctrica. Para ello, los autores realizan un estudio por simulación numérica en el que someten a la red a diferentes situaciones climatológicas extremas de manera intencionada. Como puede observarse, la dimensión temporal de todos estos problemas es clave. Sin embargo, se observan dos objetivos diferentes en todos estos trabajos. Por un lado, la estimación de la probabilidad de ocurrencia de un evento raro. Por otro, la detección de eventos raros en una ventana de tiempo fija.

En el caso de la estimación de la probabilidad de ocurrencia de un evento raro, la probabilidad es estimada por simulación. Este tema se ha tratado especialmente en la física y la ingeniería. Ejemplos de aplicaciones de estimación de la probabilidad de un evento raro son: la estimación de fallo de una infraestructura [9], la probabilidad de fallo de sistemas técnicos [10], o la probabilidad de desarrollos climáticos extremos [11].

En la clasificación de eventos raros, las instancias son series temporales [12]. El objetivo es clasificar nuevas series temporales utilizando un modelo aprendido anteriormente. Sin embargo, dada la temporalidad de las instancias, existen dos aproximaciones de clasificación diferentes. En primer lugar, se encuentra la clasificación de eventos raros completos, es decir, de series temporales completas. Por ejemplo, en [13], se hace uso del conjunto de datos SMART<sup>1</sup> para predecir si el disco duro va a fallar en un periodo de tiempo acotado. Los datos consisten en una colección de medidas tomadas a lo largo del tiempo por sensores del disco duro cuando este está en uso. En [14], se hace uso de un conjunto de datos de tecnología térmica en el que se ha almacenado información sobre sistemas de calefacción. El objetivo es predecir si el sistema de calefacción está fallando o no. En segundo lugar, la clasificación temprana de eventos raros se ha tratado en la literatura [15] (*early classification*). El objetivo es clasificar las nuevas observaciones lo antes posible, preferiblemente, antes de que se complete la serie temporal. Esta temprana clasificación es crítica en una variedad de aplicaciones. Por ejemplo, en

<sup>1</sup>El conjunto de datos SMART se compone de datos de uso de discos duros en los que se pueden ver errores como comportamiento normal.



[8] se realiza una predicción temprana de desprendimientos de tierra usando imágenes por satélite. O en [5], donde basándose en erupciones volcánicas del pasado, se predice si un volcán va a entrar en erupción o no en una ventana de tiempo fija.

De acuerdo a las distribuciones de probabilidad de los eventos raros ( $\mathcal{A}$ ) y normales ( $\mathcal{N}$ ), asumiendo que los datos son generados por el mecanismo generador  $P(\mathbf{x}, c)$  [16],  $P(C = \mathcal{A}) \ll P(C = \mathcal{N})$ , los datos cuentan con una distribución desbalanceada de las clases. Por ello, la clasificación de eventos raros se puede formalizar bajo el marco de clasificación supervisada de series temporales con un (alto) desbalanceo de probabilidad sobre las clases [17], [18].

Sin embargo, en algunos problemas de clasificación de eventos raros, las instancias se transforman de tal forma que no se tiene en cuenta la información temporal en el proceso. Por esto, la clasificación de eventos raros se puede convertir en un problema de clasificación atemporal desbalanceado [4], [8].

Para evaluar el rendimiento de los clasificadores en la detección de eventos raros, métricas populares como el AUC [14], [19], [20] y el *recall* de la clase asociada al evento raro [14], [20] son utilizadas en la literatura.

#### II-A. Características de los datos de entrada

En la mayoría de los artículos referidos a la detección de eventos raros, los datos están etiquetados en dos categorías: normal ( $\mathcal{N}$ ) y rara ( $\mathcal{A}$ ). Las instancias son series temporales, una secuencia ordenada de pares (tiempo, valor) de longitud fija  $N$ ;  $TS = \{(t_i, x_i), i = 1, \dots, N\}$  [12]. Tanto en el escenario de clasificación de eventos raros, como en el escenario de detección de anomalías, existe una distribución desbalanceada de las clases donde  $P(C = \mathcal{A}) \ll P(C = \mathcal{N})$ . En este escenario de clasificación, tanto las instancias normales como las anormales se encuentran en el conjunto de entrenamiento del modelo.

#### II-B. Técnicas

Entre las técnicas utilizadas en la literatura para estimar la probabilidad de ocurrencia de un evento raro se encuentran: *importance sampling*, simulaciones de Monte Carlo [21], [22], *kriging* [22] o *first order reliability methods (FORM)* [23]. De acuerdo con la clasificación de eventos raros, la técnica *rare event logistic regression*, una adaptación de la regresión logística, ha sido explícitamente propuesta en este escenario de clasificación [4], [8], [20], [24]. No obstante, técnicas populares de clasificación han sido aplicadas con éxito, como son la discriminación por divergencia de *Kullback-Leibler* [19], las redes neuronales de memoria a corto y largo plazo [14], los algoritmos genéticos [25], *naïve Bayes* para múltiples instancias [13], los procesos de Poisson [5], los *support vector data regression surrogates* [26], las redes Bayesianas [27], las máquinas de soporte vectorial [28] o el *AdaBoost* [29].

Por otro lado, teniendo en cuenta la distribución desbalanceada de las clases, se han encontrado técnicas en la literatura que tratan con este tipo de situaciones, como son *Structure Preserving Over Sampling (SPO)* [18] o una técnica de muestreo similar al SMOTE [17].

### III. DETECCIÓN DE ANOMALÍAS

En el escenario de detección de anomalías, comúnmente los datos son atemporales y etiquetados. El objetivo es detectar anomalías basándose en un modelo aprendido con datos históricos. El conjunto de entrenamiento se compone de tanto instancias normales como anormales (anomalías). Nótese que se espera que las instancias anómalas nuevas (no vistas) sean parecidas a aquellas provistas en el conjunto de entrenamiento del modelo. Por lo tanto, este escenario puede formalizarse bajo el marco de la clasificación supervisada con un (alto) desbalanceo de las clases, asumiendo que los datos se generan por un mecanismo generador  $P(\mathbf{x}, c)$  [16],  $P(C = \mathcal{A}) \ll P(C = \mathcal{N})$ . Esta distribución desbalanceada de los datos hace que los clasificadores estándar estén abrumados por la clase mayoritaria (anormal) e ignoren la minoritaria (normal) [30].

Para evaluar el rendimiento de los clasificadores en este escenario, dado el (alto) desbalanceo de las clases, métricas comunes como el *accuracy* no son lo suficiente representativas. Por ello, focalizándose en la correcta clasificación de las anomalías; o lo que es lo mismo, minimizando el error de tipo II, una métrica de evaluación popular utilizada en la literatura es el *recall* de la clase minoritaria [1], [31]. Sin embargo, otras métricas de evaluación pueden ser utilizadas como las que se revisan en [32].

#### III-A. Características de los datos de entrada

En la detección de anomalías, los datos son atemporales y, en la mayoría de las aplicaciones, están etiquetados en dos categorías: normal ( $\mathcal{N}$ ) y anómalo ( $\mathcal{A}$ ). En este escenario de clasificación existe una distribución desbalanceada de estas dos categorías, por lo que se tienen muchas más instancias de la clase normal que de la anormal. Sin embargo, en el conjunto de entrenamiento, se tienen tanto instancias de la clase normal como de la clase anómala.

#### III-B. Técnicas

Entre las técnicas específicas creadas bajo el entorno de detección de anomalías, se encuentra el popular *Isolation Forest* [33]. Por otro lado, se han adaptado técnicas de clasificación para resolver problemas en este ámbito, como son: las máquinas de soporte vectorial [34], los *random forests* [35], los clasificadores Bayesianos [36], las redes neuronales [37], o los modelos basados en mixturas de gaussianas [38]. Nótese que dado que la detección de anomalías se puede formalizar como un escenario de clasificación supervisada con distribuciones de probabilidad (altamente) desbalanceadas, es posible utilizar técnicas específicas para el desbalanceo, como puede ser el *Synthetic Minority Oversampling Technique (SMOTE)* [39], [40].

### IV. DETECCIÓN DE NOVEDADES

En detección de novedades, comúnmente las instancias son atemporales y durante la etapa de entrenamiento, no se proporcionan instancias anormales [2], [6], [7]. El objetivo es clasificar si una nueva instancia pertenece al conjunto

normal provisto en entrenamiento o no, basándose en un modelo aprendido únicamente con instancias de una clase. Después, el modelo debe ser capaz de detectar cualquier grupo de instancias discordantes que es posible que formen una nueva clase [41]. Nótese que quizá sea necesaria la intervención de un experto para poder consolidar esta última anotación de una nueva clase. Por ejemplo, en este estudio de neurociencia [7], una novedad se considera un estímulo que no ha sido experimentado anteriormente. Este nuevo estímulo puede compartir características con otros nuevos estímulos no vistos en momento de entrenamiento, formando una clase o un nuevo tipo de estímulo. En el control alimenticio, los objetos extraños dentro de los envoltorios de los alimentos, como las piedras, los plásticos o insectos, son considerados novedades [6]. En este caso, es posible que las piedras de un alimento tengan características parecidas a otras observaciones no vistas en el conjunto de entrenamiento que contenga también una piedra.

En la detección de novedades, el conjunto de entrenamiento es generado únicamente por  $P(\mathbf{X}|C = \mathcal{N})$ . Consecuentemente, no se posee conocimiento alguno sobre las novedades cuando se aprende el primer modelo. Por lo tanto, en la creación del modelo, se debe asumir que las novedades estarán uniformemente distribuidas en el espacio de características. Esto es razonable dado que al no poseer ninguna información a priori, cualquier suposición es inconsistente. Sin embargo, una vez que se reconocen algunas novedades, estas pueden formar una clase nueva, por lo que el problema puede pasar a ser un problema de clasificación supervisada con distribuciones de probabilidad de clases desbalanceadas [41]. Para clarificar este último concepto, considérese un estudio médico en el que se proporcionan electrocardiogramas asociados a una enfermedad concreta como conjunto de entrenamiento. En la etapa de predicción, ciertos electrocardiogramas muestran una discordancia notable con aquellos de la etapa de entrenamiento. Por lo tanto, el clasificador los etiqueta como novedades. No obstante, se sabe que estos electrocardiogramas marcados como novedad, están relacionados con otra enfermedad. Por ello, es razonable pensar que estos electrocardiogramas comparten características entre ellos y que por tanto, crear una nueva clase para representar a los mismos sería una buena aproximación.

Por otro lado, también se ha tratado la detección de novedades en un entorno dinámico o *stream*. Por ejemplo en [41], partiendo de un conjunto de clasificación supervisada, los autores detectan nuevas clases combinando técnicas de clasificación supervisada y no supervisada. En concreto, si las instancias etiquetadas como novedades son suficientemente densas y distintas a las demás, estas son etiquetadas como una nueva clase.

Finalmente, para evaluar el rendimiento de estos clasificadores, es necesario señalar que la clasificación se centra principalmente en detectar las instancias normales proporcionadas en momento de entrenamiento [3], [33], [42]. Por lo tanto, las métricas de evaluación se basan en la minimización del error de tipo I. Una medida popular es la maximización del *recall* de la clase normal [3], [42].

#### IV-A. Características de los datos de entrada

En el escenario de detección de novedades, no se provee de instancias nóveles en el conjunto de entrenamiento. El modelo es aprendido únicamente con instancias de una clase. Se espera que en momento de predicción puedan llegar tanto instancias de una como de otra (novel) clase. Sin embargo, también se espera una distribución de probabilidad desbalanceada sobre las clases normal y novel  $P(C = \mathcal{N}) \ll P(C \neq \mathcal{N})$  [7]. Además, se asume uniformidad sobre la distribución de las instancias novel.

#### IV-B. Técnicas

Las técnicas especialmente diseñadas para la detección de novedades tienen en cuenta que aprenden únicamente de una clase y son capaces de discernir si una nueva instancia forma parte o no de este comportamiento. Por lo tanto, las técnicas más representativas de este escenario de clasificación son aquellas relacionadas con el marco *one class*. Por ejemplo, *one class SVM* [28], [43], [44], *K-Nearest Neighbors data description* [45], *graph embeded one-class classifiers* [46] y *one-class random forests* [47] han sido propuestas en la literatura en escenarios de detección de novedades.

### V. DISCUSIÓN: DETECCIÓN DE OUTLIERS

El término dato atípico, *outlier* en inglés tiene características comunes a los demás términos. Por ejemplo, las instancias pueden ser tanto temporales (series temporales) [48] como atemporales [49]–[51].

No obstante, aunque similar, el término outlier tiene diferencias clave con el resto de términos analizados. La diferencia más significativa es que los datos no están etiquetados, es decir, la tarea de predicción se realiza bajo el marco de la clasificación no supervisada [49]. Por lo tanto, en contraposición al resto de escenarios, no se asume que al menos existen dos clases en el problema de predicción. En ocasiones, el término outlier también se ha relacionado con el *ruido* sugiriendo que estas observaciones pueden ser inconsistentes o incorrectas [49]. Por ejemplo, cuando se cometen errores humanos al recoger los datos, estos comportamientos erráticos son considerados outliers [52]. En cambio, en otras situaciones, el término outlier se ha relacionado con instancias con alta varianza [51], [53]. Por ejemplo en [51], los autores detectan jugadores *all-star* de la NBA en un conjunto de datos constituido por jugadores de baloncesto entre los años 1973 y 2003. Los jugadores excepcionales son considerados outliers. Para detectarlos, los autores realizan un *clustering* y aquellos puntos que se desvían significativamente son considerados outliers.

Sin embargo, la detección de los outliers es subjetiva [49]. ¿Cuánto debe desviarse una observación del resto para considerarla como atípica? En la literatura existen múltiples criterios para responder a esta pregunta [51], [54], [55]. Para clarificarla, en la Figura 1 se describen dos situaciones para la detección de outliers. En 1a el punto marcado con *A* es considerado dato atípico dada la desviación significativa hacia uno y otro grupo. No obstante, cuando existe mucha más

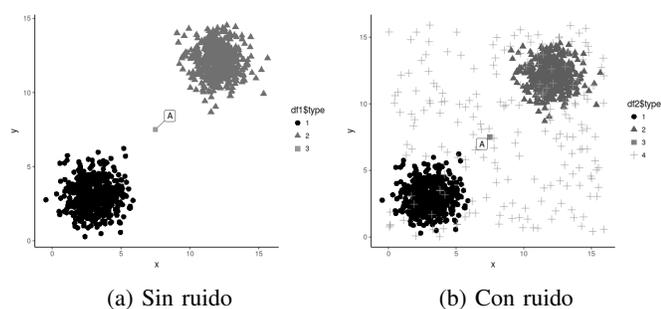


Figura 1: Diferentes escenarios de outliers. Por [49].

Cuadro I: Resumen de las características de los diferentes escenarios de aprendizaje.

	Eventos raros	Anomalías	Novedades	Outliers
Siempre relacionado con dominios temporales	✓	✗	✗	✗
Distribución desbalanceada de las clases	✓	✓	✓	-
Observaciones anormales durante la etapa de entrenamiento	✓	✓	✗	-
Se realiza predicción sobre clases previamente vistas	✓	✓	✗	✗
Clasificación supervisada	✓	✓	✓	✗

dispersión en los datos, este concepto puede ser más difuso y complejo. Este comportamiento se puede ver en 1b. En 1b, dados los demás outliers alrededor del punto A, la densidad del punto A es mayor y puede que quede difuminado el criterio de separación, haciendo una detección más difícil.

## VI. CONCLUSIONES

Por un lado, los términos eventos raros, anomalías y novedades se han utilizado para describir problemas de clasificación similares en la literatura. Por el otro, problemas similares han sido descritos con diferentes términos. Además, estos términos se han utilizado indistintamente sin tener en cuenta las características que los diferencian. Por ello, en este artículo se han remarcado las características genuinas de cada uno de los términos. Para ello, se han extraído las características que más comparten los trabajos de la literatura referidos a cada término y se han revisado los objetivos, las características de los datos de entrada, y las técnicas utilizadas en los respectivos trabajos. Además, se ha argumentado que estos escenarios de aprendizaje pueden ser formalizados como problemas de clasificación supervisada con un (alto) desbalanceo entre las distribuciones de probabilidad de las clases. Consecuentemente, las técnicas específicas para tratar el desbalanceo pueden ser adaptadas y utilizadas en estos escenarios. En la Tabla I se muestra un resumen de las principales características de los diferentes escenarios de aprendizaje tratadas en este trabajo.

## VII. AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Gobierno Vasco (IT609-13) y por el Ministerio de Economía, Industria y Competitividad (TIN2016-78365-R). Ander Carreño posee una beca del Ministerio de Economía, Industria y Competitividad (BES-2017-080016). J.A. Lozano posee financiación tanto del programa BERC 2018-2021 (Gobierno Vasco) como del programa Severo Ochoa SEV-2017-0718 (Ministerio de Economía, Industria y Competitividad).

## REFERENCIAS

- [1] R. P. Ribeiro, P. Pereira, and J. Gama, "Sequential anomalies: a study in the Railway Industry," *Machine Learning*, vol. 105, no. 1, pp. 127–153, oct 2016.
- [2] M. A. F. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko, "A review of novelty detection," *Signal Processing*, vol. 99, pp. 215–249, 2014.
- [3] S. Luca, D. A. Clifton, and B. Vanrumste, "One-class classification of point patterns of extremes," *Journal of Machine Learning Research*, vol. 17, pp. 1–21, 2016.
- [4] A. Theofilatos, G. Yannis, P. Kopelias, and F. Papadimitriou, "Predicting Road Accidents: A Rare-events Modeling Approach," in *Transportation Research Procedia*, 2016.
- [5] Y. Dzierma and H. Wehrmann, "Eruption time series statistically examined: Probabilities of future eruptions at Villarrica and Llaima Volcanoes, Southern Volcanic Zone, Chile," *Journal of Volcanology and Geothermal Research*, 2010.
- [6] H. Einarsdóttir, M. J. Emerson, L. H. Clemmensen, K. Scherer, K. Willer, M. Bech, R. Larsen, B. K. Ersbøll, and F. Pfeiffer, "Novelty detection of foreign objects in food using multi-modal X-ray imaging," *Food Control*, vol. 67, pp. 39–47, sep 2016.
- [7] A. Kafkas and D. Montaldi, "How do memory systems detect and respond to novelty?" *Neuroscience Letters*, feb 2018.
- [8] M. Van Den Eeckhaut, T. Vanwalleggem, J. Poesen, G. Govers, G. Verstraeten, and L. Vandekerckhove, "Prediction of landslide susceptibility using rare events logistic regression: A case-study in the Flemish Ardennes (Belgium)," *Geomorphology*, vol. 76, no. 3-4, pp. 392–410, 2006.
- [9] L. Dueñas-Osorio and S. M. Vemuru, "Cascading failures in complex infrastructure systems," *Structural Safety*, vol. 31, no. 2, pp. 157–167, mar 2009.
- [10] T. Bedford and R. M. Cooke, *Probabilistic risk analysis: foundations and methods*. Cambridge University Press, 2001.
- [11] S. Dessai and M. Hulme, "Does climate adaptation policy need probabilities?" *Climate Policy*, vol. 4, no. 2, pp. 107–128, jan 2004.
- [12] P. Esling and C. Agon, "Time-series data mining," *ACM Computing Surveys*, vol. 45, no. 1, pp. 1–34, nov 2012.
- [13] J. F. Murray, G. F. Hughes, and K. Kreutz-Delgado, "Machine Learning Methods for Predicting Failures in Hard Drives: A Multiple-Instance Application," *J. Mach. Learn. Res.*, 2005.
- [14] S. Zhang, S. Bahrampour, N. Ramakrishnan, L. Schott, and M. Shah, "Deep learning on symbolic representations for large-scale heterogeneous time-series event prediction," in *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, mar 2017, pp. 5970–5974.
- [15] U. Mori, "Contributions to time series data mining departing from the problem of road travel time modeling," Ph.D. dissertation, University of the Basque Country, 2015.
- [16] T. M. T. M. Mitchell, *Machine Learning*. McGraw-Hill, 1997.
- [17] S. Köknar-Tezel and L. J. Latecki, "Improving SVM classification on imbalanced time series data sets with ghost points," *Knowledge and Information Systems*, vol. 28, no. 1, pp. 1–23, jul 2011.
- [18] H. Cao, X.-L. Li, Y.-K. Woon, and S.-K. Ng, "SPO: Structure Preserving Oversampling for Imbalanced Time Series Classification," in *2011 IEEE 11th International Conference on Data Mining*. IEEE, dec 2011, pp. 1008–1013.
- [19] J. Xu, S. Denman, C. Fookes, and S. Sridharan, "Detecting rare events using Kullback-Leibler divergence: A weakly supervised approach," *Expert Systems with Applications*, 2016.

- [20] Y. Ren, Y. Wang, X. Wu, G. Yu, and C. Ding, "Influential factors of red-light running at signalized intersection and prediction using a rare events logistic regression model," *Accident Analysis and Prevention*, 2016.
- [21] M. Balesdent, J. Morio, and L. Brevault, "Rare Event Probability Estimation in the Presence of Epistemic Uncertainty on Input Probability Distribution Parameters," *Methodology and Computing in Applied Probability*, 2016.
- [22] Y. Auffray, P. Barbillon, and J. M. Marin, "Bounding rare event probabilities in computer experiments," *Computational Statistics and Data Analysis*, 2014.
- [23] D. Straub, I. Papaioannou, and W. Betz, "Bayesian analysis of rare events," *Journal of Computational Physics*, 2016.
- [24] G. King, G. Langche Zeng, J. Fowler, E. Katz, M. Tomz for research assistance, J. Alt, J. Freeman, K. Gleditsch, G. Imbens, C. Manski, P. McCullagh, W. Mebane, J. Nagler, B. Russett, K. Scheve, P. Schrodt, M. Tanner, R. Tucker for helpful suggestions, S. Bennett, P. Huth, and R. Tucker, "Logistic Regression in Rare Events Data," *Political Analysis*, vol. 9, no. 2, pp. 137–163, 2001.
- [25] G. M. Weiss and H. Hirsh, "Learning to Predict Rare Events in Event Sequences," *Proceedings of the 4th International Conference on Knowledge Discovery and Data Mining*, 1998.
- [26] J.-M. Bourinet, "Rare-event probability estimation with adaptive support vector regression surrogates," *Reliability Engineering and System Safety*, 2016.
- [27] S.-P. Cheon, S. Kim, S.-Y. Lee, and C.-B. Lee, "Bayesian networks based rare event prediction with sensor data," *Knowledge-Based Systems*, 2009.
- [28] W. Khreich, B. Khosravifar, A. Hamou-Lhadji, and C. Talhi, "An anomaly detection system based on variable N-gram features and one-class SVM," *Information and Software Technology*, 2017.
- [29] J. Wu, J. M. Rehg, and M. D. Mullin, "Learning a Rare Event Detection Cascade by Direct Feature Selection," *Neural Information Processing Systems (NIPS)*, vol. 16, 2003.
- [30] N. V. Chawla, N. Japkowicz, and A. Ko, "Editorial: Special Issue on Learning from Imbalanced Data Sets," *Sigkdd Explorations*, vol. 6, no. 1, p. 1, 2004.
- [31] A. Ogbechie, J. Díaz-Rozo, P. Larrañaga, and C. Bielza, "Dynamic Bayesian Network-Based Anomaly Detection for In-Process Visual Inspection of Laser Surface Heat Treatment," *Machine Learning for Cyber Physical Systems*, pp. 17–24, 2017.
- [32] J. Ortigosa-Hernández, I. Inza, and J. A. Lozano, "Towards competitive classifiers for unbalanced classification problems: a study on the performance scores," 2016.
- [33] D. Zhang, N. Li, Z.-H. Zhou, C. Chen, L. Sun, and S. Li, "iBAT: Detecting anomalous taxi trajectories from GPS traces," *Proceedings of the 13th International Conference on Ubiquitous Computing (UbiComp '11)*, pp. 99–108, 2011.
- [34] Y. Zhou, W. Su, L. Ding, H. Luo, and P. Love, "Predicting Safety Risks in Deep Foundation Pits in Subway Infrastructure Projects: Support Vector Machine Approach," *Journal of Computing in Civil Engineering*, vol. 31, no. 5, p. 04017052, 2017.
- [35] S. Fan, G. Liu, and Z. Chen, "Anomaly detection methods for bankruptcy prediction," *2017 4th International Conference on Systems and Informatics (ICSAI)*, no. 17, pp. 1456–1460, 2017.
- [36] N. A. Heard, D. J. Weston, K. Platanioti, and D. J. Hand, "Bayesian anomaly detection methods for social networks," *Annals of Applied Statistics*, vol. 4, no. 2, pp. 645–662, 2010.
- [37] K. Noto, C. Brodley, and D. Slonim, "FRaC: a feature-modeling approach for semi-supervised and unsupervised anomaly detection," *Data mining and knowledge discovery*, vol. 25, no. 1, pp. 109–133, 2012.
- [38] D. Reynolds, "Gaussian Mixture Models," in *Encyclopedia of Biometrics*. Boston, MA: Springer US, 2015, pp. 827–832.
- [39] S. Miri Rostami and M. Ahmadzadeh, "Extracting Predictor Variables to Construct Breast Cancer Survivability Model with Class Imbalance Problem," *Shahrood University of Technology*, vol. 6, no. 2, pp. 263–276, jul 2018.
- [40] M. Araujo, R. Bhojwani, J. Srivastava, L. Kazaglis, and C. Iber, "ML Approach for Early Detection of Sleep Apnea Treatment Abandonment," *Proceedings of the 2018 International Conference on Digital Health - DH '18*, pp. 75–79, 2018.
- [41] M. M. Masud, Q. Chen, L. Khan, C. C. Aggarwal, J. Gao, J. Han, A. Srivastava, and N. C. Oza, "Classification and Adaptive Novel Class Detection of Feature-Evolving Data Streams," *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, no. 7, pp. 1484–1497, jul 2013.
- [42] M. Swarnkar and N. Hubballi, "OCPAD: One class Naive Bayes classifier for payload based anomaly detection," *Expert Systems with Applications*, 2016.
- [43] F. Dufrenois and J. C. Noyer, "One class proximal support vector machines," *Pattern Recognition*, vol. 52, pp. 96–112, 2016.
- [44] S. M. Erfani, S. Rajasegarar, S. Karunasekera, and C. Leckie, "High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning," *Pattern Recognition*, 2016.
- [45] D. M. J. Tax, "One-class classification," 2001.
- [46] V. Mygdalis, A. Iosifidis, A. Tefas, and I. Pitas, "Graph Embedded One-Class Classifiers for media data classification," *Pattern Recognition*, vol. 60, pp. 585–595, dec 2016.
- [47] C. Désir, S. Bernard, C. Petitjean, and L. Heutte, "One class random forests," *Pattern Recognition*, vol. 46, no. 12, pp. 3490–3506, dec 2013.
- [48] M. Gupta, J. Gao, and C. C. Aggarwal, "Outlier Detection for Temporal Data : A Survey," *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, no. 1, pp. 1–20, 2013.
- [49] C. C. Aggarwal, *Outlier Analysis*. Springer International Publishing, 2017.
- [50] L. Swersky, H. O. Marques, R. J. G. B. Campello, and A. Zimek, "On the Evaluation of Outlier Detection and One-Class Classification Methods," *IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, pp. 1–10, 2016.
- [51] M. Radovanović, A. Nanopoulos, and M. Ivanović, "Reverse Nearest Neighbors in Unsupervised Distance-Based Outlier Detection," *IEEE Transactions on Knowledge and Data Engineering*, vol. 4347, no. OCTOBER, pp. 1–14, 2014.
- [52] A. Barai and D. Lopamudra, "Outlier Detection and Removal Algorithm in K-Means and Hierarchical Clustering," *World Journal of Computer Application and Technology*, vol. 5, no. 2, pp. 24–29, 2017.
- [53] X. H. Dang, I. Assent, R. T. Ng, A. Zimek, E. Schubert, Xuan Hong Dang, I. Assent, R. T. Ng, A. Zimek, and E. Schubert, "Discriminative features for identifying and interpreting outliers," *Proceedings - International Conference on Data Engineering*, pp. 88–99, mar 2014.
- [54] M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, "A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise," *Kdd*, vol. 96, no. 34, pp. 226–231, 1996.
- [55] S. Ramaswamy, R. Rastogi, and K. Shim KAIST, "Efficient Algorithms for Mining Outliers from Large Data Sets," *ACM Sigmod Record* 2000, vol. 29, no. 2, pp. 427–438, 2016.



# Una librería para el aprendizaje Multi-instancia Multi-etiqueta

Álvaro Belmonte, Amelia Zafra, Eva Gibaja, Sebastián Ventura

*Departamento de Informática y Análisis Numérico*

*Universidad de Córdoba*

Córdoba, España

**Resumen**—Este artículo presenta una librería para trabajar en la resolución de problemas de clasificación con múltiples instancias y múltiples etiquetas. Se describe el formato de datos, la arquitectura software, así como las diferentes propuestas algorítmicas que incorpora. La librería permite añadir nuevos algoritmos de forma sencilla, facilitando a los investigadores en esta área el desarrollo, prueba y comparación de nuevas propuestas. Además, es libre y de código abierto y está implementada en Java, usando las librerías Weka y Mulan. De este modo, los usuarios que trabajan tanto en el aprendizaje con múltiples instancias como en el aprendizaje con múltiples etiquetas, se encontrarán con un entorno de desarrollo con el que están familiarizados.

**Index Terms**—multi-instance learning, multi-label learning, software

## I. INTRODUCCIÓN

A medida que los problemas de clasificación se vuelven más complejos, encontrar una representación adecuada de la información se convierte en una tarea cada vez más complicada. La experiencia demuestra que una representación precisa, que sea capaz de reflejar todas las relaciones e interacciones existentes en los datos, influye directamente en una resolución más efectiva del problema. En este contexto, el aprendizaje con múltiples instancias y múltiples etiquetas (*multi-instance multi-label learning*, MIML) se presenta como una alternativa prometedora que permite realizar una formulación natural que se adapta a las condiciones particulares de la representación de objetos complejos que suelen tener los problemas reales. Entre los problemas donde ha sido aplicado con éxito destacan la categorización de textos o imágenes [1]–[3], la detección de vídeo y audio [4] o la bioinformática [5], [6].

El aprendizaje MIML introduce una mayor flexibilidad en la representación de objetos, tanto en el espacio de entrada como en el de salida, debido a los dos paradigmas de aprendizaje que combina. Por un lado, la representación basada en el aprendizaje multi-instancia (*multi-instance*, MI) [7] ofrece una alternativa a la representación de instancias simples. En el aprendizaje MI un objeto o patrón, conocido habitualmente como *bolsa*, es representado mediante un conjunto variable de instancias, todas ellas con el mismo número de atributos. De este modo, un objeto puede ser representado con descripciones alternativas [7], con diferentes componentes [2], o bien mostrando su evolución en el tiempo [8]. Por otro lado, el aprendizaje multi-etiqueta (*multi-label*, ML) [9] introduce una mayor flexibilidad, esta vez en el espacio de salida, permitiendo que cada patrón tenga la posibilidad de

pertenecer de forma simultánea a varias clases (etiquetas). Por ejemplo, para la resolución del problema de clasificación de imágenes, una imagen podría ser representada mediante múltiples instancias donde cada instancia se correspondería con diferentes regiones de la imagen, pudiendo a su vez tener diferentes etiquetas, tales como nubes, leones, y paisajes.

Actualmente, existen herramientas que permiten resolver problemas utilizando el aprendizaje MI y ML. Así, Weka [10] permite trabajar con problemas MI, y las librerías MEKA [11] y MULAN [12] permiten abordar el aprendizaje ML. No obstante, ninguna de ellas permite trabajar con el aprendizaje MIML. Hasta donde los autores conocemos, los únicos algoritmos públicamente disponibles para resolver problemas MIML han sido desarrollados por el grupo de investigación LAMDA [13]. Las principales limitaciones de estas implementaciones son que: están codificados en Matlab, con lo que es necesario disponer de licencia de este software para poder ejecutarlos y están formados por paquetes independientes, que habitualmente contienen la implementación de un único algoritmo que utiliza un formato de entrada y salida distinto al de otros paquetes, lo que dificulta la tarea de poder realizar un estudio experimental con ellos.

En este contexto, este artículo presenta una librería para aprendizaje MIML basada en las librerías Weka y MULAN, con lo que los investigadores en MI y ML, que empleen las librerías anteriores, estarán familiarizados con su estructura y formato. Entre sus características más relevantes se puede destacar: que utiliza un formato de datos diseñado específicamente para este aprendizaje, que cuenta con un conjunto de algoritmos desarrollados que directamente pueden ser ejecutados, que permite el uso de los algoritmos implementados para aprendizaje MI y ML de Weka y Mulan en un contexto MIML, que facilita el diseño y desarrollo de nuevos modelos que resuelvan problemas de clasificación con una representación MIML, que permite llevar a cabo un estudio experimental utilizando validación cruzada, y finalmente, su uso y ejecución resultan sencillos mediante la configuración de ficheros *xml*.

El resto del artículo se organiza como sigue. En la sección 2 se describe diferentes algoritmos MIML propuestos en la literatura. La sección 3, muestra la descripción de la librería, considerando el formato de los datos, su funcionalidad, su arquitectura y los principales paquetes y elementos de los que consta. En la sección 4, se describe algunos ejemplos de uso. Finalmente, la sección 5 describe las conclusiones más

relevantes del trabajo realizado.

## II. TRABAJO PREVIO

Los algoritmos de clasificación desarrollados para aprendizaje MIML se pueden clasificar en dos enfoques [14]. Por un lado, algoritmos basados en una estrategia de transformación del problema MIML, y por otro lado, algoritmos que abordan el problema MIML directamente.

Debido a que tanto el aprendizaje MI como el aprendizaje ML son parte de MIML, se pueden usar como vía o puente para la transformación y posterior resolución de problemas MIML. Una primera aproximación consiste en aplicar alguna técnica de descomposición de etiquetas que transforme el problema MIML a un problema MI. Después de esto, puede ser utilizado cualquier algoritmo MI para resolver el problema. Otra aproximación consiste en emplear alguna técnica que permita unificar las diferentes instancias de una bolsa en una única instancia, transformando el problema MIML en un problema ML al que se le puede aplicar cualquier algoritmo de ML. En la literatura se pueden encontrar diferentes algoritmos que realizan una transformación del problema, entre ellos encontramos métodos basados en *ensembles* [15], [4], máquinas de vector soporte [5] y métodos basados en redes neuronales [1].

El rendimiento de los algoritmos anteriores puede verse limitado debido a la pérdida de información incurrida durante el proceso de simplificación/transformación. Idealmente, las conexiones entre instancias y etiquetas, así como la correlación entre las propias etiquetas deberían ser tenidas en cuenta. Por este motivo, también se han propuesto técnicas para abordar el problema MIML de forma directa basadas en redes neuronales [16], *ensembles* [6], máquinas de vector soporte [3] o vecinos más cercanos [2]. En [17] puede encontrarse una revisión más exhaustiva de algoritmos publicados en el aprendizaje MIML.

## III. DESCRIPCIÓN DE LA LIBRERÍA

En esta sección se comentará el formato de los datos, los algoritmos y funcionalidades que se encuentran implementados, los paquetes de los que se compone y el formato de los ficheros de configuración para ejecutar cualquiera de sus algoritmos de clasificación.

### III-A. Formato de los datos

El formato diseñado para la representación de la estructura de un problema MIML está basado en los formatos de datos utilizados por Weka y MULAN. De este modo, un conjunto de datos estará representado mediante dos ficheros:

- Un fichero *xml* cuya función principal es identificar a los atributos del fichero *arff* que representan las etiquetas. De esta manera, las etiquetas no tienen por qué ser necesariamente los últimos atributos que se definan. Además, este fichero permite representar, anidando etiquetas, una jerarquía de clases. A continuación, se muestra un ejemplo con la definición de cuatro etiquetas.

```
<?xml version="1.0" encoding="utf-8"?>
<labels xmlns="http://mulan.sourceforge.net/labels">
  <label name="label1"></label>
  <label name="label2"></label>
  <label name="label3"></label>
  <label name="label4"></label>
</labels>
```

- Un fichero *arff* (*Attribute-Relation File Format*) cuya estructura presenta dos partes, cabecera y datos:
  - La **cabecera** contiene el nombre de la relación junto con una lista de atributos y sus tipos.
    - En la primera línea del fichero se encuentra la sentencia *@relation <relation-name>* que define el nombre del conjunto de datos. Es una cadena de caracteres que, si contiene espacios, debe de ir entrecomillada.
    - A continuación, se definen dos atributos: el primero de tipo nominal que identifica unívocamente a cada bolsa y el segundo atributo, relacional, que contiene los atributos que describen a las instancias. Para definir los atributos se utilizan las sentencias *@attribute <attribute-name><data-type>*. Habrá una línea por atributo:
      - ◇ Los tipos de dato numérico se especifican con *numeric*.
      - ◇ Si se trata de un conjunto posible de valores nominales debe ir especificado entre llaves y separado por comas. Por ejemplo:  $\{valor_1, valor_2, \dots, valor_N\}$ .
      - Finalmente, se definen los atributos correspondientes a las etiquetas. Estos atributos tienen que ser de tipo binario (nominales con valores 0 y 1).
  - La sección de **datos** comienza con un *@data*. Cada una de las líneas siguientes representará una bolsa. Los atributos deben de estar ordenados según la declaración realizada en la cabecera. El valor de cada atributo se separa por comas y todas las filas deben tener el mismo número de columnas. Los decimales deben de separarse con el punto. El contenido del atributo relacional estará entrecomillado (comillas simples o dobles), separando cada instancia de la bolsa por un  $\backslash n$ . A continuación, se muestra un ejemplo de fichero *arff* donde cada bolsa está formada por tres atributos de tipo numérico y tiene cuatro etiquetas. La primera bolsa está formada por 3 instancias, y la segunda bolsa por 2 instancias.

```
@relation toy
@attribute id {bag1,bag2}
@attribute bag relational
  @attribute f1 numeric
  @attribute f2 numeric
  @attribute f3 numeric
@end bag
@attribute label1 {0,1}
@attribute label2 {0,1}
@attribute label3 {0,1}
@attribute label4 {0,1}
```



@data

bag1,"42,-198,-109\n42,-191,-142\n3,4,6",1,0,0,1

bag2,"12,-98,10\n42,-19,-12",0,1,1,0

La librería cuenta con las clases necesarias tanto para representar bolsas individuales (clase *Bag* del paquete *data*) como para representar un conjunto de datos completo (clase *MIMLInstances*). También proporciona medios para guardar un conjunto de datos en sus respectivos ficheros *arff* y *xml* y para obtener diferentes métricas que te permitan estudiarlos en más profundidad (*MIMLStatistics* en *data.statistics*).

### III-B. Funcionalidad incluida en la librería

La librería contiene métodos para transformar un conjunto de datos MIML a otro tipo de representación como MI o ML, algoritmos de clasificación MIML y clases para dar soporte al desarrollo de experimentos.

**III-B1. Métodos para transformar datos MIML:** se han incluido los siguientes métodos:

- Métodos para transformar a MI (formato de datos usado en Weka) [9]:
  - *Binary Relevance Transformation*: transforma un conjunto de datos MIML en tantos conjuntos de datos MI binarios como etiquetas tenga el problema.
  - *Label Powerset Transformation*: transforma un conjunto de datos MIML en uno multiclase en el que cada posible combinación de etiquetas del conjunto de datos original es considerado una clase diferente.
- Métodos para transformar a ML (formato de datos usado en MULAN) [18]:
  - *Arithmetic Transformation*: transforma cada bolsa en una única instancia donde el valor para cada atributo es su valor medio dentro de la bolsa.
  - *Geometric Transformation*: transforma cada bolsa en una única instancia donde el valor para cada atributo es el centro geométrico de sus valores máximo y mínimo dentro de la bolsa.
  - *Min-Max Transformation*: transforma cada bolsa en una única instancia que contiene, para cada atributo, sus valores mínimo y máximo dentro de esa bolsa. Cada instancia está definida por el doble de atributos de los que tenía previamente.

**III-B2. Algoritmos de clasificación:** se han incluido los siguientes algoritmos:

- *MIMLClassifierMI*: realiza una transformación del problema MIML para obtener un problema MI aplicando una transformación LP o BR. Posteriormente, obtiene un resultado resolviendo el problema con un algoritmo MI que se especifique. Al ser compatible con la librería Weka, en la tabla I se muestra un ejemplo de 15 algoritmos de Weka que podrían ser utilizados directamente este clasificador.
- *MIMLClassifierML*: realiza una transformación del problema MIML para obtener un problema ML aplicando una transformación aritmética, geométrica o min-max.

Posteriormente, obtiene un resultado resolviendo el problema con un algoritmo ML que se especifique. Al ser compatible con la librería MULAN, en la tabla I se muestra un ejemplo de 15 algoritmos de MULAN que podrían ser utilizados directamente este clasificador.

- *MIML-kNN* [2]: utiliza los vecinos y referencias más cercanos a una bolsa para estimar las posibles clases a las que pertenece, trabajando directamente sobre datos MIML.

**III-B3. Otra funcionalidad:** la librería presenta un marco de trabajo para manejar conjuntos de datos MIML, obtener informes, calcular medidas de distancia, realizar experimentos utilizando validación cruzada o indicando los conjuntos de datos de entrenamiento y test, así como las clases e interfaces genéricas y necesarias para desarrollar nuevos clasificadores, que permite que el desarrollo de nuevas propuestas y la realización de un estudio experimental sea una tarea sencilla.

### III-C. Arquitectura de la librería

La librería, desarrollada en Java y de código abierto, hace uso de las librerías MULAN y Weka. Se encuentra estructurada en siete paquetes, algunos de ellos organizados en subpaquetes, de acuerdo con su funcionalidad:

- **core**: incluye diferentes funcionalidades que serán utilizadas por otras clases de la librería. Este paquete contiene las clases relacionadas con la configuración de los métodos utilizando ficheros *xml*.
- **core.distance**: contiene diferentes variantes de la distancia de *Hausdorff* para calcular la distancia entre bolsas.
- **data**: incluye clases para trabajar con el formato de datos detallado en la sección III-A. Entre las funcionalidades que soporta se encuentra: cargar en memoria un conjunto de datos, conocer propiedades de los datos como el número de instancias de una bolsa concreta, el número de atributos, el número de bolsas totales, el número de etiquetas, etc. Además, permite acceder tanto a una bolsa particular, como a sus instancias y etiquetas.
- **data.statistics**: incluye clases encargadas de obtener información relevante de los conjuntos de datos MIML. Se considera tanto información referente a MI (atributos por

Tabla I: Algoritmos compatibles

Clasificadores MI (Weka)	Clasificadores ML (MULAN)
CitationKNN	BRkNN
MDD	DMLkNN
MIDD	IBLR
MIBoost	mLkNN
MIEMDD	HOMER
MILR	RAKEL
MINND	EPS
MIOptimalBall	ECC
MIRI	MLStacking
MISMO	BR
MISVM	LP
MITI	PS
MIWrapper	CC
SimpleMI	RPC





```
<configuration>
  <classifier> </classifier>
  <evaluator> </evaluator>
  <report> </report>
</configuration>
```

Todos los ficheros deben empezar con el elemento *configuration*. En la etiqueta *classifier*, se especificará el clasificador de la librería que se quiere utilizar. Dentro del clasificador será donde se detalle su configuración: los parámetros específicos que necesite, el método de transformación a utilizar, y/o el clasificador MI o ML que se requiera en las versiones que transforman el problema. La etiqueta *evaluator* detallará el conjunto de datos a utilizar, y si se lleva a cabo una validación cruzada o se especifican directamente los ficheros *train/test*. Finalmente, la etiqueta *report*, indicará el informe que genera el fichero de salida. Esta clase puede ser extendida fácilmente para que los usuarios especifiquen el formato de salida más conveniente.

#### IV. EJEMPLOS DE USO

La experimentación mediante ficheros *xml* se puede llevar a cabo haciendo uso de la clase ejecutable *RunAlgorithm* pasándole como argumento, a través de la opción *-c*, la ruta del fichero de configuración. A continuación, se mostrarán ejemplos para un conjunto de casos ilustrativos.

##### IV-A. Ejecución de un algoritmo de clasificación MIML reduciendo el problema a MI

El ejemplo de fichero *xml* para este caso es el siguiente:

```
<configuration>
  <classifier name="mimlclassifier.mimlTomi.MIMLClassifierMI"
  >
    <multiInstanceClassifier name="weka.classifiers.mi.MISMO">
      <listOptions>-C 1.0 -L 0.001 -P 1.0E-12 -N 0 -V
        -1 -W 1 -K "weka.classifiers.mi.supportVector.
        MIPolyKernel -E 1.0 -C 250007"</listOptions>
    </multiInstanceClassifier>
    <transformMethod name="mulan.classifier.transformation.
      BinaryRelevance"/>
  </classifier>
  <evaluator method="train-test">
    <data>
      <trainFile>data/miml_03_data.arff</trainFile>
      <testFile>data/miml_04_data.arff</testFile>
      <xmlFile>data/miml_03_data.xml</xmlFile>
    </data>
  </evaluator>
  <report name="report.BaseMIMLReport">
    <fileName>results/results.csv</fileName>
  </report>
</configuration>
```

- El clasificador que se desea utilizar debe especificarse en el atributo *name* del elemento *classifier*. Se va a emplear el clasificador *MIMLClassifierMI*. Este clasificador necesita que se especifique en *transformMethod* el método de transformación que se va a utilizar para transformar el problema MIML en un problema MI. En el ejemplo se hace uso del método BR de la librería de Mulan.

- Como configuración de este algoritmo, se debe detallar también en la etiqueta *multiInstanceClassifier* el algoritmo MI que se utilizará una vez realizada la transformación. En este caso se ha utilizado MISMO, un clasificador de la librería Weka para problemas MI. En la etiqueta *listOptions* detallaremos los parámetros que se quieren utilizar en el algoritmo MISMO. Si no se detalla ninguno, se tomarán los valores por defecto establecidos para cada algoritmo.
- El atributo *method* de la etiqueta *evaluator* especifica el proceso de evaluación que se llevará a cabo.
- En el caso de que se vaya a realizar un método *train/test* es necesario especificar en la etiqueta *data*, que pertenece al *evaluator*, la ruta de los ficheros *arff* de entrenamiento y test, así como la del fichero *xml* con las etiquetas.
- Por último, en el elemento *report* se indicará el informe que se desea utilizar, y la configuración de cada informe. En el informe que se ha especificado en el ejemplo, solamente es necesario especificar en *fileName* la ruta donde se quiere guardar el informe de resultados.

##### IV-B. Ejecución de algoritmo degenerativo utilizando ML

Para la realización de un experimento utilizando ML como vía, un ejemplo de fichero de configuración sería:

```
<configuration>
  <classifier name="mimlclassifier.mimlTomi.MIMLClassifierML"
  >
    <multiLabelClassifier name="mulan.classifier.lazy.MLkNN">
      <parameters>
        <classParameters>int.class</classParameters>
        <classParameters>double.class</classParameters>
        <valueParameters>1</valueParameters>
        <valueParameters>1.0</valueParameters>
      </parameters>
    </multiLabelClassifier>
    <transformMethod name="transformation.mimlTomi.
      ArithmeticTransformation"/>
  </classifier>
  <evaluator method="cross-validation">
    <numFolds>5</numFolds>
    <data>
      <file>data/miml_03_data.arff</file>
      <xmlFile>data/miml_03_data.xml</xmlFile>
    </data>
  </evaluator>
  <report name="report.BaseMIMLReport">
    <fileName>results/results.csv</fileName>
  </report>
</configuration>
```

- En este caso, el elemento *multiInstanceClassifier* es sustituido por *multiLabelClassifier*.
- En caso de que el clasificador ML que se utilice se pueda configurar, los parámetros se deben de especificar de la siguiente forma (para respetar la forma de ejecución que tiene establecida MULAN):
  - En primer lugar se pondrán tantos elementos *classParameters* como parámetros tenga el constructor del clasificador. Su contenido debe de ser el tipo al que

pertenecen dichos parámetros, tienen que estar en el orden en el que se declaren en el constructor.

- A continuación, se especifican los valores que se quiere que tengan dichos parámetros, indicando cada uno de ellos en un elemento *valueParameters* diferente que, nuevamente, tienen que estar en orden.
- El clasificador que se ha utilizado (*MIMLClassifierML*) se adapta a todos los métodos de transformación disponibles en *transformation.mimlToml*, es necesario especificar en su configuración el elemento *transformMethod*.
- Este experimento se ha configurado para que realice una evaluación basada en validación cruzada, especificado en el atributo *method* la cadena "cross-validation". Es necesario indicar el número de *folders* en el elemento *numFolds* y el fichero que contiene el conjunto de datos. La etiqueta *report* sería similar al ejemplo anterior.

#### IV-C. Ejecución de algoritmo basado en vecinos más cercanos

Por último, se muestra un ejemplo de fichero *xml* para ejecutar el algoritmo MIMLkNN:

```
<configuration>
  <classifier name="mimlclassifier.lazy.MIMLkNN">
    <nReferences>2</nReferences>
    <nCitters>2</nCitters>
    <metric name="core.distance.AverageHausdorff">
    </metric>
  </classifier>
  <evaluator method="train-test">
    <data>
      <trainFile>data/miml_03_data.arff</trainFile>
      <testFile>data/miml_04_data.arff</testFile>
      <xmlFile>data/miml_03_data.xml</xmlFile>
    </data>
  </evaluator>
  <report name="report.BaseMIMLReport">
    <fileName>results/results.csv</fileName>
  </report>
```

- Con los algoritmos que trabajen directamente con el formato MIML tan solo es necesario especificar en su configuración los parámetros para su ejecución. En este ejemplo, el algoritmo MIML-kNN necesita configurar el número de referencias y citas con los que trabajará, así como la métrica que va a utilizar para medir la distancia entre las bolsas de una *data set*. Las etiquetas *evaluator* y *report*, serían similares a los ejemplos anteriores.

#### V. CONCLUSIONES

En este trabajo se presenta una librería Java basada en Weka y Mulan para el desarrollo, prueba y comparación de algoritmos dentro del marco de trabajo del aprendizaje MIML. Además de un conjunto de algoritmos MIML, de referencia en la temática, la estructura de la librería permite el desarrollo de nuevas propuestas de forma sencilla. Finalmente, se ha diseñado un formato de datos específico para MIML. La librería es sencilla de utilizar mediante el uso de ficheros de configuración *xml*.

#### AGRADECIMIENTOS

Este trabajo está financiado por el proyecto de investigación TIN2017-83445-P del Ministerio de Economía y Competitividad y el Fondo Europeo de Desarrollo Regional.

#### REFERENCIAS

- [1] K. Yan, Z. Li, and C. Zhang. A new multi-instance multi-label learning approach for image and text classification. *Multimedia Tools and Applications*, 75(13):7875–7890, 2016.
- [2] M.L. Zhang. A k-nearest neighbor based multi-instance multi-label learning algorithm. In *Proceedings of the 22nd International Conference on Tools with Artificial Intelligence*, volume 2, pages 207–212, 2010.
- [3] C. Tong-tong, L. Chan-juan, Z. Hai-lin, Z. Shu-sen, L. Ying, and D. Ximiao. A multi-instance multi-label scene classification method based on multi-kernel fusion. In *Proceedings of the Conference on Intelligent Systems*, pages 782–787, 2015.
- [4] X.S. Xu, X. Xue, and Z. Zhou. Ensemble multi-instance multi-label learning approach for video annotation task. In *Proceedings of the 19th International Conference on Multimedia*, pages 1153–1156. ACM, 2011.
- [5] Y.X. Li, S. Ji, S. Kumar, J. Ye, and Z.H. Zhou. Drosophila gene expression pattern annotation through multi-instance multi-label learning. *Transactions on Computational Biology and Bioinformatics*, 9(1):98–112, 2012.
- [6] J.S. Wu, S.J. Huang, and Z.H. Zhou. Genome-wide protein function prediction through multi-instance multi-label learning. *Transactions on Computational Biology and Bioinformatics*, 11(5):891–902, 2014.
- [7] T.G. Dietterich, R.H. Lathrop, and T. Lozano-Pérez. Solving the multiple instance problem with axis-parallel rectangles. *Artificial Intelligence*, 89(1):31–71, 1997.
- [8] S. Kotsiantis, D. Kanellopoulos, and V. Tampakas. Financial application of multi-instance learning: two greek case studies. *Journal of Convergence Information Technology*, 5(8):42–53, 2010.
- [9] E. Gibaja and journal=Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery volume=4 number=6 pages=411–444 year=2014 publisher=Wiley Online Library Ventura, S. Multi-label learning: a review of the state of the art and ongoing research.
- [10] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I.H. Witten. The weka data mining software: An update. *SIGKDD Explorations Newsletter*, 11(1):10–18, 2009.
- [11] J. Read, P. Reutemann, B. Pfahringer, and G. Holmes. Meka: a multi-label/multi-target extension to weka. *Journal of Machine Learning Research*, 17(1):667–671, 2016.
- [12] G. Tsoumakas, E. Spyromitros-Xioufis, Jozef Vilcek, and I. Vlahavas. Mulan: A java library for multi-label learning. *Journal Machine Learning Research*, 12:2411–2414, 2011.
- [13] LAMDA Learning and Mining from Data. <http://lamda.nju.edu.cn/Data.ashx>. Accessed: 2018-06-19.
- [14] Z.H. Zhou, M.L. Zhang, S.J. Huang, and Y.F. Li. Multi-instance multi-label learning. *Artificial Intelligence*, 176(1):2291–2320, 2012.
- [15] Z.H. Zhou and M.L. Zhang. Multi-instance multi-label learning with application to scene classification. In *Proceedings of the Advances in neural information processing systems*, pages 1609–1616, 2006.
- [16] C. Li and G. Shi. Weights optimization for multi-instance multi-label rbf neural networks using steepest descent method. *Neural Computing and Applications*, 22(7-8):1563–1569, 2013.
- [17] F. Herrera, S. Ventura, R. Bello, C. Cornelis, A. Zafra, D. Tarragó, and S. Vluymans. *Multiple Instance Learning. Foundations and Algorithms*. Springer, 230 pages, 2016.
- [18] Eibe Frank and Xin Xu. Applying propositional learning algorithms to multi-instance data. pages 1–13. *Computer Science Working Papers. University of Waikato, Department of Computer Science*. 2003.

**IX Simposio de  
Teoría y Aplicaciones  
de la Minería de Datos  
(IX TAMIDA)**

TAMIDA 7:  
DEEP LEARNING







# Una primera aproximación a la predicción de variables turísticas con Deep Learning

Daniel Trujillo, Antonio Jesús Rivera, Francisco Charte, María José del Jesus

*Instituto Andaluz de Investigación en Ciencia de Datos e Inteligencia Computacional (DaSCI), Departamento de Informática  
Universidad de Jaén*

Jaén, España

{dtviedma,arivera,fcharte,mjjesus}@ujaen.es

**Resumen**—El turismo es una de las actividades económicas más importantes a nivel mundial, por lo que una correcta planificación de los recursos existentes en función de la demanda es fundamental. En este sentido, el trabajo desarrollado permite comparar la bondad de un nuevo modelo de *deep learning*, LSTM, frente a un modelo clásico ampliamente reconocido, ARIMA. Se ha llevado a cabo un proceso de entrenamiento para obtener los modelos LSTM y ARIMA que, posteriormente se han validado utilizando datos no disponibles durante el aprendizaje.

Nuestros resultados muestran que los nuevos modelos LSTM obtienen una precisión mayor que el clásico ARIMA, tanto en la validación a priori como en la predicción posterior.

**Palabras clave**—LSTM; ARIMA; time series forecasting

## I. INTRODUCCIÓN

La industria del turismo a nivel mundial se considera una de las actividades económicas más importantes, sólo superado por la industria del petróleo y productos derivados [2], según algunos autores. En el caso español, al sector turístico se vinculan un 12,1% del total de empleos en 2013, creciendo desde 9,8% en 2001 [3]. En una actividad tan importante es fundamental una correcta planificación, de manera que, por un lado, se pueda atender adecuadamente a la demanda, y por otro, se pueda realizar el mantenimiento del patrimonio que da lugar a la actividad turística.

Por su naturaleza, de este tipo de actividades emanan conjuntos de datos con una fuerte dependencia temporal, lo que también se conoce como **series temporales** [?]. En estos conjuntos de datos, las instancias aparecen ordenadas por un criterio cronológico, al tiempo que la variable de estudio presenta una fuerte dependencia cronológica. Ejemplos de este tipo de conjuntos de datos son la evolución del precio de un bien, del número de pasajeros de un aeropuerto, o del grado de ocupación hotelera en una provincia concreta.

Tradicionalmente, el método que se ha utilizado para analizar este tipo de conjuntos de datos ha sido ARIMA [4]. Este modelo integra análisis de medias móviles y análisis autoregresivo, conocido como modelo ARMA, y lo generaliza para series diferenciadas. Este modelo, junto con las estrategias heurísticas desarrolladas para encontrar sus mejores

parámetros, tiene una muy importante fundamentación estadística y se le considera como el estado del arte en el ámbito de predicción de series temporales.

Por su parte, las técnicas de *deep learning* han supuesto una revolución importante en el campo del aprendizaje automático, gracias a evoluciones en los algoritmos de entrenamiento disponibles, así como el aumento de la potencia de cómputo de los ordenadores actuales. Esta combinación de factores posibilitan el uso de estos modelos capaces de reproducir procesos cognitivos complejos reservados a los humanos. Modelos de *deep learning* han conseguido resultados sorprendentes en tareas como el reconocimiento de escritura [5], lo cual los hace prometedores sucesores de los algoritmos tradicionales de aprendizaje automático.

Uno de estos modelos, LSTM (*Long Short Term Memory*), está especialmente diseñado para tareas de análisis de series temporal. Su estructura le permite almacenar conocimiento útil para razonar sobre una serie temporal con un contexto mayor que las técnicas tradicionales, estableciendo una nueva línea de estudio que quizás termine por suceder al actual estado del arte, el modelo ARIMA.

El objeto de este estudio es establecer una comparativa entre el algoritmo más comúnmente usado en predicción de series temporales, ARIMA, y las redes neuronales de tipo LSTM, en un problema real de predicción de datos turísticos de interés para la provincia de Jaén.

Este artículo se estructura de la siguiente forma: En la segunda sección se aportará una breve introducción de los métodos considerados en el estudio. A continuación, se detallará la experimentación llevada a cabo para establecer la comparativa, tras lo cual se mostrarán los resultados obtenidos para finalizar con una discusión de los mismos.

## II. MÉTODOS

En esta sección se aporta una descripción a nivel introductorio de los métodos que utilizaremos para llevar a cabo la experimentación, LSTM y ARIMA. Al no ser objetivo de este estudio proporcionar una descripción suficientemente detallada, se aportan las referencias más relevantes en cada caso.

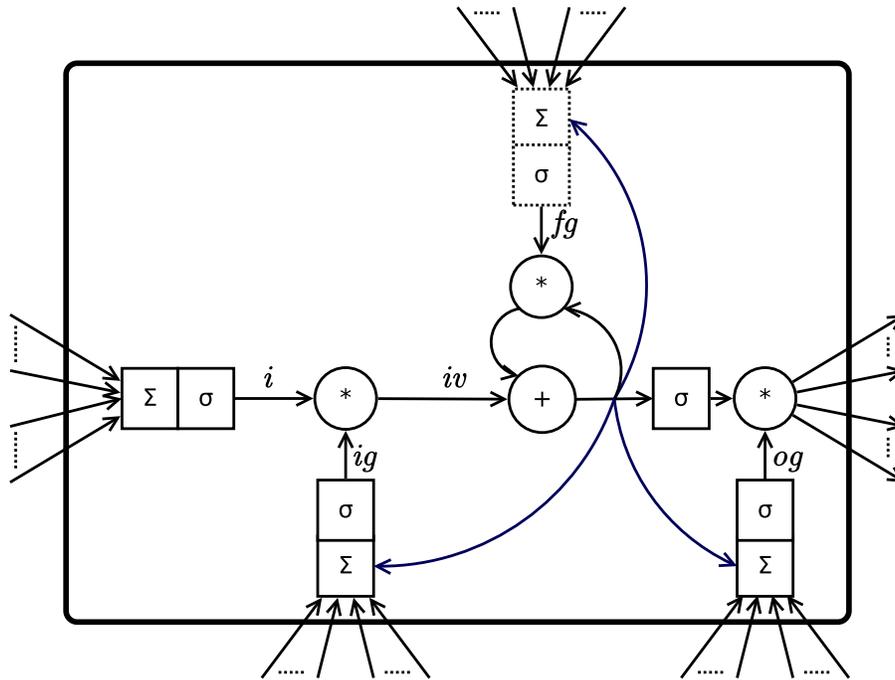


Fig. 1. Representación esquemática de una neurona tipo LSTM.

#### A. LSTM

Las redes neuronales de tipo LSTM surgen como respuesta a los diversos problemas en torno al flujo del gradiente que sufren los algoritmos de aprendizaje basados en gradiente de redes neuronales artificiales, los cuales se discuten ampliamente en [6], siendo el más recurrente en este tipo de redes el llamado "vanishing gradient". Este problema hace referencia al decreciente efecto de las variaciones de un parámetro en la salida final de la red, en la medida en la que el parámetro se aleja de la salida de la red. Esto afecta a las capas de entrada de redes prealimentadas con un número elevado de capas, pero también a redes neuronales recurrentes con amplias dependencias temporales en los datos de entrada.

Las redes neuronales de tipo LSTM han supuesto un importante impulso para las redes neuronales recurrentes, ya que, por los motivos expuestos, los algoritmos de entrenamiento de redes neuronales recurrentes más utilizados no ofrecían ninguna ventaja práctica frente a los mismos algoritmos en redes neuronales prealimentadas [6].

Long Short Term Memory es una arquitectura de neurona artificial cuya estructura le permite mantener un estado interno formado a partir de las evaluaciones que se han realizado, y que influye en las posteriores. Esta estructura le permite memorizar conocimiento que utilizará y actualizará en evaluaciones posteriores.

En su formulación original [7], esta célula define un flujo de información a través del cual, los valores de entrada se modifican mediante operaciones multiplicativas y funciones de activación para obtener su salida.

Sin embargo, posteriores modificaciones a la estructura original se han incorporado de facto en esta formulación,

dando lugar a la estructura LSTM más utilizada en la literatura actual, que consta de los siguientes elementos:

- *Input, input gate, forget gate* y *output gate*: unidades simples, que primeramente aplican pesos a los valores de entrada, a los que se suman el valor de salida de CEC resultado de la última evaluación del CEC (*peephole connections*), y posteriormente aplica una función de activación.
- CEC (*Constant Error Carrousel*): situado en la parte central de la neurona, está formado por una autoconexión recurrente. Esta autoconexión constituye la memoria de la neurona, cuyo valor se suma a la entrada del CEC y se actualiza en cada evaluación de la neurona a su salida.

En la fig. 1 se detalla el interior de una neurona LSTM. En ella se puede apreciar muy fácilmente el flujo de información dentro de la neurona, de izquierda a derecha, mientras es transformada por las 3 válvulas de información. Asimismo, se puede ver el CEC, justo en el centro de la neurona.

A continuación se proporciona una descripción textual de la neurona LSTM:

- 1) Los valores de entrada se suministran a las unidades *input*, *input gate* y *forget gate*, obteniendo los valores  $i$ ,  $ig$  y  $fg$ , respectivamente
- 2)  $i$  e  $ig$  se combinan multiplicando sus valores elemento a elemento, obtenido  $iv$ .
- 3)  $fg$  se multiplica, elemento a elemento, con el valor de salida del CEC en el instante de tiempo anterior, obteniendo el nuevo valor de entrada de CEC.
- 4) Este valor de entrada de CEC se suma con  $iv$ , elemento a elemento, obteniendo la salida de CEC. Ésta, además de continuar por el flujo de información, se copia a



las *input*, *forget* y *output gate* a través de las *peephole connections*.

- 5) Se calcula la salida del *output gate*, *og*, dados los valores originales de entrada y el nuevo valor de salida del *CEC* a través de las *peephole connection*.
- 6) Por último, la salida de *CEC* se suministra a una función de activación, cuyo resultado se multiplica elemento a elemento con *og* para obtener la salida final de toda la neurona LSTM.

Esta estructura interna está diseñada para trabajar con series de datos en intervalos mucho más amplios, ya que se asegura, junto con un entrenamiento adecuado, generalmente mediante *backpropagation*, un flujo de error constante en el *CEC*, mientras que la *input gate* protege el valor recordado en el *CEC* de entradas irrelevantes, y la *output gate* protege a otras células de valores irrelevantes en el *CEC*.

Esta descripción de la estructura estándar es producto, como se ha mencionado antes, de modificaciones sobre la estructura original que se define en [7]. Dichas modificaciones incluyen:

- *Forget gate*: Previamente a su introducción en [8], el valor de salida del *CEC* simplemente se copia a la entrada del *CEC*, mientras que este valor, agregado a los datos de entrada, se suministran a una función de activación. Tras su introducción, se elimina la función de activación, y la salida del *CEC* pasa a ser simplemente la agregación del valor anterior del *CEC* a los datos de entrada.
- *Peephole connections*: Son conexiones con peso desde la salida del *CEC* hasta las *input gate* y *forget gate*, donde se usarán en la siguiente evaluación; y hasta la *output gate*, donde se usará inmediatamente para calcular el valor *og* y la salida final de la LSTM.

## B. ARIMA

ARIMA [4] es un modelo ampliamente utilizado en la literatura, por su especial bondad en tareas de predicción de series temporales. El funcionamiento general de este modelo consiste en aproximar la serie temporal mediante una función matemática que pueda ser evaluada en las condiciones que se desean predecir. Esto significa que ARIMA no sólo es útil en tareas predictivas, sino que el ajuste que realiza de la serie temporal puede ser analizado desde un punto de vista descriptivo.

ARIMA se construye a partir de otro modelo, llamado ARMA, generalizándolo para series temporales que han sido diferenciadas. Esto es, una serie temporal obtenida como las diferencias entre cada elemento y el anterior de la serie temporal inicial. El nombre de ARMA proviene de las iniciales *AutoRegressive and Moving Averages*, y consiste en encontrar, primeramente un modelo autoregresivo sobre las diferencias de los valores a predecir, y posteriormente modelar el error de la anterior regresión a través de un modelo de medias móviles.

## III. EXPERIMENTACIÓN

Para conocer el desempeño de los algoritmos se han realizado ejecuciones de ambos sobre un conjunto de datos real,

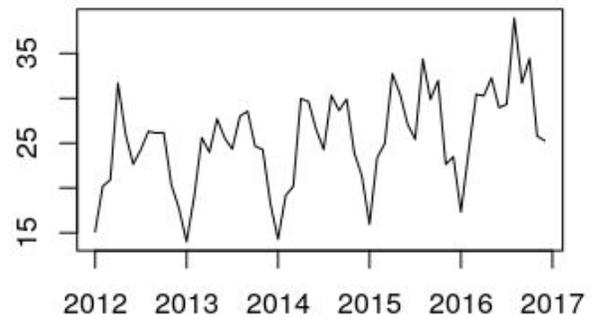


Fig. 2. Visualización de la serie temporal.

obteniendo para cada una de las ejecuciones unas métricas de error que serán objeto de comparación más adelante.

Con el objeto de hacer la comparativa lo más justa posible, el criterio que se ha utilizado a la hora de seleccionar los mejores parámetros del modelo LSTM es la precisión de predicción en el conjunto de entrenamiento. Tras seleccionar los mejores conjuntos de parámetros según este criterio, se ha procedido a reevaluar los modelos en el conjunto de test. De este modo el conjunto de test no interviene en el entrenamiento, como es natural, pero tampoco interviene en la selección del modelo, simulando con mayor precisión un escenario real cuyo objetivo sea el de predecir valores futuros.

### A. Métricas de error

En la elaboración de esta experimentación se han considerado 2 métricas de error distintas: La raíz del error cuadrático medio (*rmse*); y el error porcentual absoluto medio (*mape*).

Las métricas de error cuantifican el desvío de una muestra (en este caso, representa la predicción realizada por nuestros modelos) con respecto de otra (los valores reales para la serie temporal).

Siendo  $E$  el vector de valores esperados y  $P$  el vector de valores predichos, teniendo  $E$  y  $P$  el mismo número de valores, ambas métricas se definen como sigue:

1) *RMSE*:

$$RMSE(E, P) = \sqrt{MSE(E, P)} \quad (1)$$

$$MSE(E, P) = \frac{\sum_{i=1}^n (E_i - P_i)^2}{n} \quad (2)$$

2) *MAPE*:

$$MAPE(E, P) = \frac{100}{n} \sum_{i=1}^n \frac{E_i - P_i}{E_i} \quad (3)$$

### B. Conjunto de datos

Los datos empleados se han obtenido del repositorio público de Instituto Nacional de Estadística. En concreto, se han utilizado los relativos a la Encuesta de Ocupación Hotelera, serie correspondiente al grado de ocupación por plazas de la provincia de Jaén. Estos datos han sido agrupados por la fuente en intervalos de tiempo de un mes, siendo este intervalo la resolución de la que disponemos. En la fig. 2 se puede ver una representación de los datos obtenidos.

Como cabe esperar de una serie temporal relacionada con el sector turístico, se puede apreciar a simple vista una periodicidad de 12 meses en los valores, además de picos de ocupación en los meses de marzo-abril y julio-agosto, correspondiente con los períodos vacacionales de semana santa y verano.

De todos los datos disponibles, se han utilizado los comprendidos entre enero de 2012 y diciembre de 2016. Posteriormente, se han construido 2 conjuntos de datos: El primero de ellos es el conjunto de entrenamiento, y está formado por los datos comprendidos entre enero de 2013 y diciembre de 2015. El resto de datos, los comprendidos entre enero y diciembre de 2016 compondrán el conjunto de datos de test.

A las series temporales extraídas se les han añadido regresores externos adicionales para aumentar la eficiencia de los métodos. Estas columnas adicionales se han decidido con cuidado de no introducir incertidumbre en el conjunto de datos, considerando sólo aquellos regresores que se puedan obtener de forma precisa de antemano. En concreto, se ha añadido información sobre:

- Año
- Mes del año
- Semana santa: Indica si el mes en cuestión contiene parte de la semana santa de ese año.
- Puentes largos: Número de festivos en días martes o jueves en el mes dado.
- Puentes cortos: Número de festivos en días lunes o viernes en el mes dado.

Si bien esta es la estructura general de los conjuntos de datos de partida, por exigencias de cada implementación la estructura se ha adaptado en cada caso:

**LSTM:** Cada instancia suministrada a la red durante el entrenamiento tiene la forma  $(V_n, V_{n-1}, V_{n-11}, V_{n-12}, SS, PC, PL)$ , mientras que para la predicción se elimina el valor  $V_n$  por motivos obvios.

**ARIMA:** En el caso de ARIMA, cada instancia tiene la forma  $(V_n, V_{n-12}, SS, PC, PL)$

Siendo:

- $n$  El mes correspondiente a la instancia en cuestión.
- $V_i$  El valor de la serie temporal correspondiente al mes  $i$ -ésimo.
- $SS$  Indica si en ese mes tiene lugar la Semana Santa.
- $PC$  El número de puentes cortos del mes correspondiente.
- $PL$  El número de puentes largos del mes correspondiente.

En el caso de la LSTM, se ha optado por añadir el valor de la serie temporal de mes anterior, del año anterior, y del undécimo mes anterior. Esta selección de retardos obedece a los resultados de un análisis preliminar de autocorrelación de la serie temporal, fig. 3, que muestra que estos valores son los más significativos.

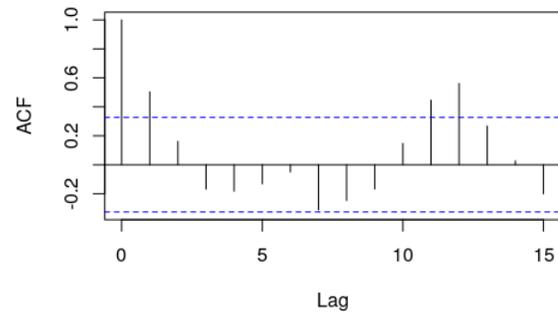


Fig. 3. Función de autocorrelación.

### C. Métodos

La experimentación con las redes neuronales recurrentes de tipo LSTM se ha implementado en *Python*, utilizando la librería *Keras* con el backend *TensorFlow*, configurado por defecto. Asimismo, se ha utilizado la librería *Pandas* para la gestión de los datos, *Numpy* para el cálculo numérico, *Matplotlib* para la visualización de los resultados y *Scikit-learn* para el cálculo de métricas de error, así como la normalización de los datos de entrada.

A pesar de que las redes neuronales recurrentes LSTM son un modelo de tipo *deep learning*, el tiempo de entrenamiento por modelo en esta experimentación no ha sido excesivo.

Una vez realizadas ejecuciones preliminares explorando distintas zonas del espacio de configuraciones de parámetros, a la vista de las métricas de error obtenidas, se ha procedido a seleccionar la región del espacio donde encontraremos los modelos que calculen las mejores predicciones:

- Número de LSTM: 25, 50 y 100
- Iteraciones: 100 y 200
- *batch\_size*: 1 y 2

Dado que el algoritmo utilizado para el entrenamiento de las redes LSTM, *BackPropagation Through Time*, parte de un estado inicial aleatorio, para reducir el efecto del azar de los elementos del estado inicial de la red, se han realizado 20 ejecuciones con cada una de las combinaciones de parámetros del espacio de búsqueda reducido definido anteriormente. De esta forma el error medio obtenido está muy escasamente influenciado por algunas ejecuciones cuyos resultados pueden verse desviados por motivos del azar.

Para el entrenamiento del modelo ARIMA se ha utilizado el entorno R de computación estadística, en lugar del lenguaje Python, como se ha hecho anteriormente. Esto es debido a que la implementación de referencia del modelo ARIMA está desarrollada en este lenguaje. En concreto, se ha utilizado la función *auto.arima* del paquete *forecast* [4].

El programa de entrenamiento del modelo ARIMA es visiblemente más simple que en el caso de la red LSTM. Esto es debido a que todo el análisis de parámetros y entrenamiento del modelo se realiza de forma automática por la implementación elegida, utilizando técnicas como las descritas en los trabajos [10], [11]. La existencia de distintas heurísticas



TABLA I  
RESULTADOS EJECUCIONES LSTM - RMSE ENTRENAMIENTO

Num LSTM	Iterac.	batch size	RMSE	
			Promedio	Desv. Est.
25	200	1	2,17954	0,01534
50	200	1	2,18941	0,01802
25	200	2	2,19675	0,01309
50	200	2	2,20690	0,00849
100	200	1	2,21396	0,03308
100	200	2	2,22174	0,01000
25	100	1	2,22621	0,01257
50	100	1	2,23581	0,01208
25	100	2	2,23769	0,01105
100	100	1	2,24942	0,02027
50	100	2	2,24990	0,01107
100	100	2	2,27130	0,01539

TABLA II  
RESULTADO EJECUCIÓN ARIMA

Entrenamiento	Test	
RMSE	RMSE	MAPE
2,40561	1,89010	5,01111

hace posible que este proceso se pueda automatizar teniendo en cuenta métricas comparativas como *Akaike information criterion* [12]

Además, dado que ni ARIMA ni las heurísticas que buscan los mejores parámetros son probabilísticos, no es necesario realizar varias ejecuciones del algoritmo, ya que todas arrojarían exactamente los mismos resultados.

#### IV. RESULTADOS

En la tabla I se pueden ver los resultados de las mejores ejecuciones conseguidas con redes neuronales de tipo LSTM. En ella se muestra, para la métrica de error RMSE en la partición de entrenamiento del conjunto de datos, el promedio y la desviación típica de 20 repeticiones completas del experimento. Los distintos modelos se muestran en la tabla ordenados según el error cometido en la experimentación. A la vista de estos resultados, seleccionamos el modelo de menor error para la comparativa con ARIMA.

En la tabla II se muestra el resultado de la ejecución realizada con el modelo ARIMA. Como se ha introducido antes, dado que este modelo no es probabilístico, carece de sentido realizar varias repeticiones, ya que todas predicen exactamente igual, por lo que las métricas obtenidas serán idénticas.

La tabla comparativa III se muestran los resultados obtenidos en la partición de test, tanto para el modelo ARIMA como para el mejor modelo LSTM, el cual se ha seleccionado siguiendo el criterio del menor error en la partición de entrenamiento (tabla I). Es fácil observar de esta forma que LSTM obtiene mejores resultados que ARIMA en ambas métricas de error consideradas.

#### V. CONCLUSIÓN

En este artículo se ha realizado una comparativa entre un nuevo modelo de red neuronal recurrente, LSTM, y el

TABLA III  
COMPARATIVA ARIMA - LSTM

	RMSE	MAPE
LSTM	1,70039	4,61407
ARIMA	1,89010	5,01111

algoritmo considerado estado del arte en predicción de series temporales, ARIMA, sobre un problema de predicción de series temporales en turismo, justificado por la importancia del sector turístico en la economía mundial.

Los resultados de la experimentación llevada a cabo, resumidos en la tabla III, indican que un modelo de red neuronal de tipo LSTM, seleccionado basándonos exclusivamente en datos de entrenamiento, obtiene una mayor precisión en la predicción de los datos de test que el modelo ARIMA clásico, ampliamente utilizado en el campo de series temporales.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de España de Ciencia y Tecnología bajo el proyecto TIN2015-68454-R.

#### REFERENCIAS

- [1] S. Hochreiter and J. Schmidhuber, "LSTM can solve hard long time lag problems," in *Advances in neural information processing systems*, 1997, pp. 473–479.
- [2] C. Altés, "Marketing y turismo," *Madrid: Editorial Síntesis*, 1993.
- [3] J. R. Cuadrado Roura, J. M. López Morales *et al.*, "El turismo, motor del crecimiento y de la recuperación de la economía española," 2015.
- [4] R. J. Hyndman, Y. Khandakar *et al.*, *Automatic time series for forecasting: the forecast package for R*. Monash University, Department of Econometrics and Business Statistics, 2007, no. 6/07.
- [5] V. V. Romanjuk, "Training data expansion and boosting of convolutional neural networks for reducing the mnist dataset error rate," *Naukovi Visti NTUU KPI*, no. 6, pp. 29–34, 2016.
- [6] S. Hochreiter, Y. Bengio, P. Frasconi, J. Schmidhuber *et al.*, "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies," 2001.
- [7] J. Schmidhuber and S. Hochreiter, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [8] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget: Continual prediction with LSTM," 1999.
- [9] J. Brownlee, "Multivariate time series forecasting with lstms in keras-machine learning mastery," *Machine Learning Mastery*, 2017.
- [10] E. J. Hannan and J. Rissanen, "Recursive estimation of mixed autoregressive-moving average order," *Biometrika*, vol. 69, no. 1, pp. 81–94, 1982.
- [11] V. Gómez, *Automatic model identification in the presence of missing observations and outliers*. Ministerio de Economía y Hacienda, Dirección General de Análisis y Programación Presupuestaria, 1998.
- [12] H. Akaike, "Information theory and an extension of the maximum likelihood principle," in *Selected Papers of Hirotugu Akaike*. Springer, 1998, pp. 199–213.
- [13] J. E. Ball, D. T. Anderson, and C. S. Chan, "Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community," *Journal of Applied Remote Sensing*, vol. 11, no. 4, p. 042609, 2017.

# Detección de cáncer de piel usando técnicas de aprendizaje profundo

1<sup>st</sup> Alejandro Polvillo Hall  
Departamento de Datos  
Geographica  
Sevilla, España  
alejandro@geographica.gs

2<sup>nd</sup> Juan A. Álvarez-García  
Dpto. de Lenguajes y Sistemas Informáticos  
Universidad de Sevilla  
Sevilla, España  
jaalvarez@us.es

3<sup>rd</sup> Cristina Rubio-Escudero  
Dpto. de Lenguajes y Sistemas Informáticos  
Universidad de Sevilla  
Sevilla, España  
crubioescudero@us.es

**Resumen**—El aprendizaje profundo ha sido muy utilizado para la clasificación de imágenes a partir de la competición ImageNet en 2012. Esta clasificación de imágenes es de gran utilidad en el campo de la medicina, en el que ha habido un gran crecimiento de uso de técnicas de minería de datos en los últimos años. En este trabajo seleccionamos y entrenamos una red de aprendizaje profundo para el análisis de un conjunto de datos de cáncer de piel, obteniendo resultados muy satisfactorios, ya que el modelo ha superado los resultados de clasificación de dermatólogos entrenados haciendo uso de un dermatoscopio, de otras técnicas de aprendizaje automático, y de otras técnicas de aprendizaje profundo.

**Index Terms**—aprendizaje profundo, imágenes médicas, análisis de datos clínicos

## I. INTRODUCCIÓN

El aprendizaje profundo ha sido utilizado en el campo de la visión por computadora durante décadas [5], [9]. Sin embargo, su verdadero valor no se había descubierto hasta la competición de ImageNet en 2012 [8], un éxito que provocó una revolución a través del uso eficiente del procesamiento de unidades gráficas (GPU). El principal poder del aprendizaje profundo radica en su arquitectura [10], [11], que permite discriminación en múltiples niveles de abstracción para un conjunto de características.

Las técnicas de aprendizaje profundo han sido utilizadas con éxito en campos como el de la medicina, en el que el aprendizaje profundo viene a solucionar problemas que presentan los algoritmos de aprendizaje automático con algunas estructuras de datos muy utilizadas en medicina como son las imágenes. La minería de datos clínicos es la aplicación de técnicas de minería de datos a los datos clínicos, con el objetivo de interpretar los datos disponibles. Permite la creación de modelos de conocimiento y proporciona asistencia para la toma de decisiones clínicas. En los últimos 10 años, ha habido un interés creciente en la aplicación de técnicas de minería de datos a los datos clínicos. MEDLINE ha visto un fuerte aumento de factor 10 en el número de trabajos con el término "minería de datos." en su título [7].

Para hacer un entrenamiento completo, el aprendizaje profundo requiere una gran cantidad de datos de entrenamiento

etiquetados, un requisito que puede ser difícil para cumplir en el campo de la medicina, donde la anotación de expertos es costosa y las enfermedades (por ejemplo, lesiones) no cuentan con grandes conjuntos de datos. Además, requiere una gran cantidad de recursos computacionales para que el entrenamiento no sea excesivamente lento.

En este trabajo hemos aplicado técnicas de aprendizaje profundo para analizar un conjunto de datos de imágenes de cáncer de piel, obteniendo resultados muy satisfactorios.

En las siguientes secciones describimos las metodologías y resultados obtenidos.

## II. METODOLOGÍA

En esta sección se describen las metodologías utilizadas para el desarrollo de este trabajo.

### II-A. Tensorflow

Tensorflow [1] es uno de los mejores frameworks de aprendizaje profundo existente. Ha sido adoptado por un montón de grandes empresas como Airbus, Twitter, IBM y otras más debido a su flexibilidad y polivalencia. Tensorflow es desarrollado por Google, que la usa en todos sus proyectos de aprendizaje automático y aprendizaje profundo.

Tensorflow no es en sí un framework de aprendizaje profundo, es un framework que te permite trabajar de forma muy rápida con matrices gracias a su paralelización en GPU's. Como casi todos los cálculos realizados para entrenar y predecir con una red neuronal son cálculos matriciales hacen de esta herramienta que sea ideal para usarla en la construcción de redes neuronales.

Tensorflow tiene un paquete interno que viene con la funcionalidad necesaria para hacer funcionar una red neuronal convolucional: Capas convolucionales, optimizadores, funciones de optimización, etc. . .

Una desventaja de Tensorflow es que es necesario escribir mucho código para conseguir algo funcional. El hecho de escribir todo ese código hace que tengas un control total sobre todos los elementos de la arquitectura de la red neuronal. Aunque también puede hacer que cometas muchos errores.



## II-B. Keras

Keras [2] es un framework específico de aprendizaje profundo. No es competidor de Tensorflow, pues Keras se ejecuta “encima” de Tensorflow. Keras provee una sintaxis extremadamente fácil para la creación de redes neuronales, y después convierte esta sintaxis a modelos de Tensorflow, usando la potencia de éste para ejecutar toda la maquinaria de aprendizaje.

Debido a que nuestro caso de uso será un caso de uso de red neuronal, y no necesitaremos en principio la manipulación a muy bajo nivel de los modelos de aprendizaje profundo, nosotros optamos por el uso de Keras para el desarrollo del presente proyecto.

## III. RESULTADOS

El conjunto de datos seleccionado para evaluar nuestra propuesta ha sido el conjunto de imágenes de cáncer de piel de The International Skin Imaging Collaboration (ISIC) (<https://isic-archive.com/>). Es una plataforma que intenta aunar a los profesionales dermatológicos con el objetivo de luchar contra el cáncer de piel. El conjunto de datos está formado por 23906 imágenes. Además de las imágenes, se proporcionan algunos metadatos entre los que destacamos edad, sexo, lugar anatómico del melanoma, tipo de diagnóstico, clase de melanoma y espesor del melanoma.

En primer lugar analizamos el conjunto de datos con respecto a la clase benigno/maligno. Como se puede observar en la Figura 1 está muy desbalanceado.

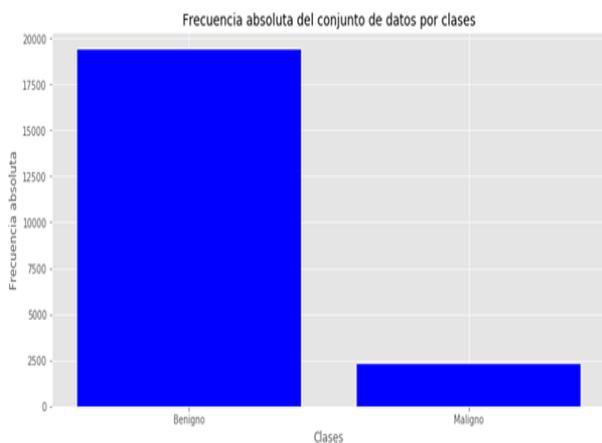


Figura 1. Conjunto de datos de cáncer de piel desbalanceado.

Debido a esto recurrimos a una técnica de remuestreo sobre la clase minoritaria que se encarga de escoger elementos al azar con reemplazo y añadirlos a la clase minoritaria. La ventaja de ésta técnica es que no elimina información, simplemente refuerza la información existente sobre la clase minoritaria. Tras aplicar la técnica el resultado obtenido se puede ver en la Figura 2.

En segundo lugar, partimos el conjunto de datos en entrenamiento (80%) y test (20%) asegurándonos de mantener balanceadas las clases en cada uno de los conjuntos.

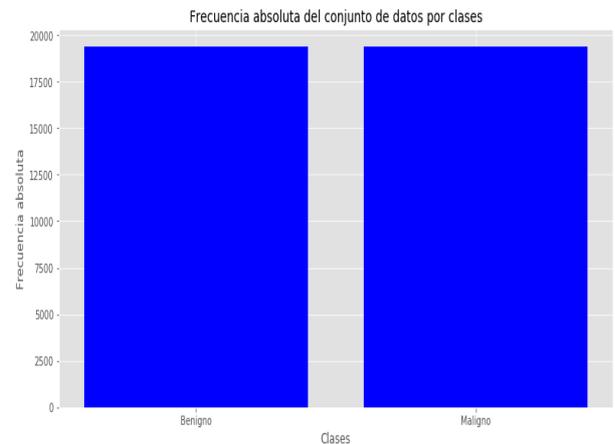


Figura 2. Conjunto de datos de cáncer de piel después del balanceo.

En tercer lugar, aplicamos un mecanismo de aumento de datos consistente en realizar distintas transformaciones aleatorias sobre cada uno de los elementos del conjunto de entrenamiento. Al realizar transformaciones aleatorias sobre el conjunto de datos conseguimos un doble efecto: aumentar el tamaño de nuestros datos y hacer que el sistema generalice mucho mejor. En particular aplicamos las técnicas conocidas como rotación automática, traslación vertical y horizontal de píxeles, cizallamiento, zoom, volteo, filtro de sal y pimienta.

### III-A. Selección y aplicación del modelo de aprendizaje profundo

A la hora de enfrentarse a la selección del modelo nos encontramos en un momento de incertidumbre máxima debido a que son muchos los parámetros que tenemos que elegir, entre estos parámetros se encuentran:

- Arquitectura de la red neuronal: Propia, InceptionV3, VGG16, VGG19, Xception, etc...
- Tipo de entrenamiento: Transferencia de conocimiento, desde cero, etc...
- Parámetros de la transferencia de conocimiento: capas a entrenar, entrenamiento completo, etc...
- Algoritmo de aprendizaje: Descenso del gradiente, RMS-Prop, Adagrad, etc...
- Parámetros del algoritmo de aprendizaje: Tasa de aprendizaje, funciones de activación, épocas, lotes, etc...

Para seleccionar los parámetros adecuados hemos utilizado la búsqueda por rejilla (o grid search en inglés). Esta técnica se basa en la definición de un conjunto de posibles valores que pueden tomar los parámetros, y generar el producto cartesiano de todos los valores de todos los parámetros entre sí, usando cada uno de estos conjuntos de parámetros generados para construir un modelo y evaluar la bondad. En la Tabla I podemos ver todos los parámetros que se han considerado a la hora de buscar el modelo más adecuado.

En nuestra búsqueda rejilla se han fijado 3 parámetros: épocas, lotes y funciones de activación. Las épocas se han fijado puesto que es obvio que a más épocas mejor van a

Cuadro I  
PARÁMETROS CONSIDERADOS EN LA BÚSQUEDA DEL MODELO MÁS ADECUADO

Parámetro	Valores
Modelo	Xception, VGG16, VGG19 y InceptionV3
Tipo de entrenamiento	Transferencia de conocimiento, desde cero
Capas a entrenar	1, 2, 3 y todas
Algoritmo de aprendizaje	Descenso del gradiente, RMSProp, Adam, Adagrad
Tasa de aprendizaje	0.00001, 0.0001, 0.001, 0.01 y 0.1
Épocas	2
Lotes	10
Funciones de activación	ReLU

Cuadro II  
MODELO Y PARÁMETROS SELECCIONADOS

Parámetro	Valores
Modelo	InceptionV3
Tipo de entrenamiento	Transferencia de conocimiento
Capas a entrenar	todas
Algoritmo de aprendizaje	Adam
Tasa de aprendizaje	0.0001
Épocas	2
Lotes	10
Funciones de activación	ReLU

funcionar los modelos en su mayoría, así que se fijan a 2 épocas, para que así todas puedan recorrer el conjunto de datos 2 veces. Los lotes van de la mano de la capacidad de la unidad de procesamiento gráfico, aunque pueden influir en el entrenamiento, en este caso se han hecho los cálculos para que el conjunto de lotes sea el máximo que la unidad de procesamiento gráfica puede soportar, así hacemos que el tiempo de búsqueda por rejilla sea menor. La función de activación la he fijado a la función de activación ReLu debido a que todas las arquitecturas usan la ReLu debido a que el aprendizaje se realiza de una manera más rápida con este tipo de función de activación.

El modelo y parámetros que mejor desempeño han tenido, obteniendo un 81 % de exactitud se puede ver en la Tabla II:

El modelo seleccionado como óptimo es el modelo de Inception V3, creado por Google. Tal y como se describe en [12] era de esperar que se seleccionara la transferencia de conocimiento en vez del entrenamiento desde cero, pues posiblemente tenga un desempeño mayor. También se recomienda que, aunque se parta de unos pesos definidos (por la transferencia de conocimiento), se permita el reajuste de algunos pesos en las capas convolucionales, con el objetivo de que se adapte a nuestro problema. Como algoritmo de aprendizaje se usa Adam, con una tasa bastante pequeña. Esta tasa tan pequeña es debido a que gracias a la transferencia de conocimiento estamos muy cerca del óptimo, queremos dar pasos muy pequeños para acercarnos cada vez más al óptimo.

Una vez con nuestro modelo y parámetros definidos, procedemos a aumentar el número de épocas con el objetivo de obtener un mejor modelo y poder evaluar en la siguiente sección. Una vez el entrenamiento del modelo ha finalizado, hemos aplicado el clasificador sobre el conjunto de pruebas, obteniendo los resultados que se pueden ver en la Figura 3.

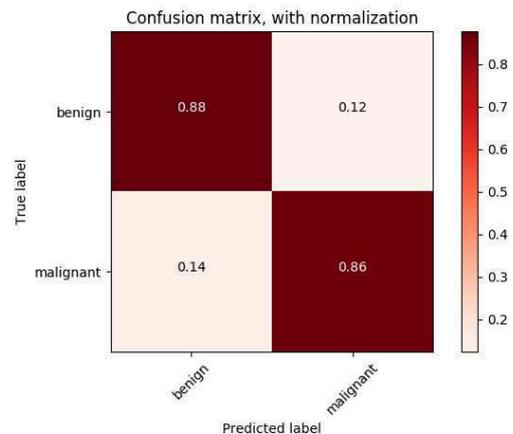


Figura 3. Matriz de confusión normalizada.

### III-B. Evaluación del modelo

A continuación hablamos sobre la evaluación del modelo. La exactitud es la métrica por defecto que usa Keras para representar la bondad del modelo a lo largo de las distintas épocas de entrenamiento. En la Figura 4 podemos observar cómo se comporta el clasificador respecto a la exactitud a lo largo de las distintas épocas para los conjuntos de validación y de entrenamiento.

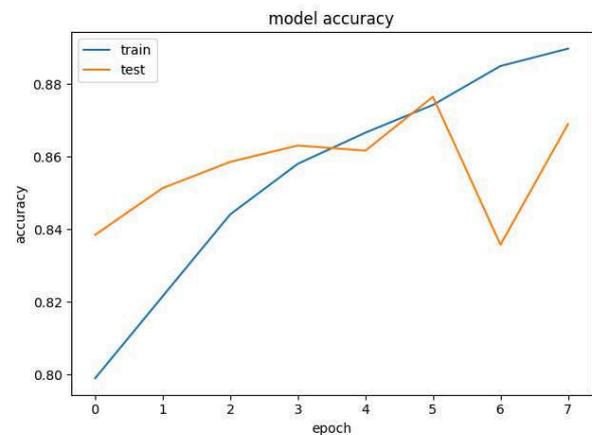


Figura 4. Exactitud del modelo a lo largo de las distintas épocas.

Como se puede observar en la gráfica siempre se encuentran en crecimiento, exceptuando en la época 6 que el conjunto de prueba hace algo difícil de interpretar, pero en la siguiente época se recupera.

El clasificador se ha puesto a entrenar durante 10 épocas, pero hemos activado una opción que permite ahorrar recursos. Esta opción consiste en que, si el clasificador durante la etapa de clasificación comienza a permanecer durante algún tiempo sin variar su exactitud, se para la etapa de aprendizaje cuando se acabe la época. Por eso se puede observar que, aunque se haya puesto a entrenar durante 10 épocas, en la gráfica sólo se observan 8.



Cuadro III  
RESULTADOS OBTENIDOS POR NUESTRO MODELO DE APRENDIZAJE PROFUNDO.

Medida	Valor
Exactitud	86.90 %
Precisión	87.47 %
Sensitividad	86.14 %
Especificidad	87.66 %
Área ROC	0.87

Se proporcionan también las medidas que se pueden ver en la Tabla III con respecto al desempeño de nuestro modelo de aprendizaje profundo.

La Figura 5 representa el área bajo la curva ROC

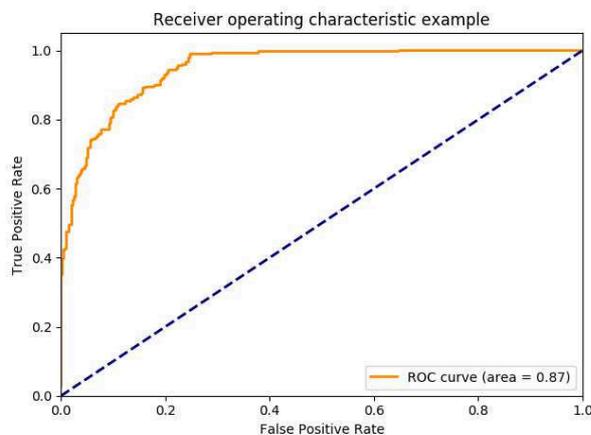


Figura 5. Área bajo la curva ROC.

Las inspecciones visuales sin ayuda de los expertos dermatológicos obtienen una media de un 60 % de exactitud [3], debido a la complejidad de observación de características diferenciadoras a simple vista. Con la ayuda de un experto entrenado junto a un dermatoscopio, la exactitud puede aumentar hasta un 75 % - 84 %.

Partiendo de la base de las afirmaciones anteriormente expuestas, y de las métricas obtenidas por nuestro clasificador, podemos observar a simple vista que nuestro clasificador ha superado en acierto a un experto dermatológico entrenado haciendo uso de un dermatoscopio. Esto parece un buen punto de partida.

Sabiendo que nuestro clasificador es capaz de superar a un experto dermatólogo, procedemos ahora a comparar nuestro clasificador con otras técnicas.

La primera intuición al intentar aplicar técnicas de inteligencia artificial en el análisis de imágenes médicas es usar aprendizaje automático o aprendizaje profundo. Con lo cual usaremos estos dos enfoques con el objetivo de comparar nuestro clasificador y ver qué bueno o malo es respecto a otros clasificadores

En primer lugar, nos centraremos en la comparación de nuestro clasificador con las técnicas de aprendizaje automático.

Cuadro IV  
COMPARACIÓN DE RESULTADOS ENTRE APRENDIZAJE PROFUNDO Y APRENDIZAJE AUTOMÁTICO.

Medida	Nuestro clasificador	Aprendizaje automático
Exactitud	86.90 %	77 %
Precisión	87.47 %	71 %
Sensitividad	86.14 %	73 %

Cuadro V  
COMPARATIVA ENTRE RESULTADOS DE NUESTRO APRENDIZAJE PROFUNDO Y OTRO APRENDIZAJE PROFUNDO.

Medida	Nuestro clasificador	Otro clasificador
Exactitud	86.90 %	85.5 %
Precisión	87.47 %	63.7 %
Sensitividad	86.14 %	50.7 %
Especificidad	87.66 %	94.1 %
Área ROC	0.87	0.8

El aprendizaje automático sobre el conjunto de datos de ISIC ha obtenido las métricas que se pueden ver en la Tabla IV [4].

Como se puede observar en la tabla, nuestro clasificador supera con creces a los clasificadores de aprendizaje automático enfocados al análisis de imágenes médicas para el conjunto de datos de ISIC. el resultado es lógico, pues los algoritmos de aprendizaje automático no están pensados para extraer características de imágenes, por lo que siempre se presupone un rendimiento menor.

En segundo, compararemos nuestro clasificador con otro clasificador de aprendizaje profundo [6]. El clasificador con el que compararemos nuestro clasificador, es un clasificador usado por un equipo participante de la competición de ISIC. Los resultados se pueden ver en la Tabla V:

Se puede observar, que, aunque el desempeño en la exactitud en ambos clasificadores es parecido, nuestro clasificador se comporta mucho mejor en la mayoría de situaciones. Ellos han conseguido obtener una especificidad muy alta, que es lo que le permite compensar la sensibilidad para obtener una exactitud y AUC ROC bastante aceptables.

#### IV. CONCLUSIONES

En este trabajo hemos presentado el resultado de aplicar técnicas de aprendizaje profundo a un conjunto de datos de imágenes de cáncer de piel. Se ha descrito la fase de preprocesamiento de los datos, selección de parámetros para el modelo seleccionado y se han calculado distintas métricas para los resultados obtenidos.

En las métricas se pueden observar que el clasificador es bastante homogéneo, y no hay resultados de difícil interpretación. El clasificador tiene un nivel de acierto en ambas clases bastante estable, lo que nos hace indicar que ha generalizado correctamente la detección de cáncer en las imágenes. Nuestro modelo ha superado los resultados de clasificación de dermatólogo entrenado haciendo uso de un dermatoscopio, de otras técnicas de aprendizaje automático, y de otras técnicas de aprendizaje profundo.

En definitiva, el clasificador se ha comportado de manera muy buena frente a este conjunto de imágenes respecto a

otros clasificadores y técnicas. Aún sabiendo que las imágenes médicas son complicadas de tratar, el clasificador ha sabido generalizar los detalles que separan una imagen de un paciente que padece cáncer de piel de otro que no lo padece, consiguiendo así predecir con exactitud en la mayoría de casos.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por los proyectos del Ministerio de Economía y Competitividad TIN2014-55894-C2-1-R y TIN2017-82113-C2-1-R.

#### REFERENCIAS

- [1] Martín Abadi, Paul Barham, Jianmin Chen, Zhifeng Chen, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Geoffrey Irving, Michael Isard, et al. Tensorflow: A system for large-scale machine learning. In *OSDI*, volume 16, pages 265–283, 2016.
- [2] François Chollet et al. Keras, 2015.
- [3] Noel CF Codella, David Gutman, M Emre Celebi, Brian Helba, Michael A Marchetti, Stephen W Dusza, Aadi Kalloo, Konstantinos Liopyris, Nabin Mishra, Harald Kittler, et al. Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic). In *Biomedical Imaging (ISBI 2018), 2018 IEEE 15th International Symposium on*, pages 168–172. IEEE, 2018.
- [4] Machine Learning for ISIC Skin Cancer Classification Challenge. <https://hackernoon.com/machine-learning-for-isic-skin-cancer-classification-challenge-part-1-ccddea4ec44a>.
- [5] Kunihiko Fukushima and Sei Miyake. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In *Competition and cooperation in neural nets*, pages 267–285. Springer, 1982.
- [6] David Gutman, Noel CF Codella, Emre Celebi, Brian Helba, Michael Marchetti, Nabin Mishra, and Allan Halpern. Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (isbi) 2016, hosted by the international skin imaging collaboration (isic). *arXiv preprint arXiv:1605.01397*, 2016.
- [7] Jimison Iavindrasana, Gilles Cohen, Adrien Depeursinge, H Müller, R Meyer, and Antoine Geissbuhler. Clinical data mining: a review. *Yearbook of medical informatics*, 18(01):121–133, 2009.
- [8] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pages 1097–1105, 2012.
- [9] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *nature*, 521(7553):436, 2015.
- [10] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [11] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, et al. Going deeper with convolutions. *Cvpr*, 2015.
- [12] Nima Tajbakhsh, Jae Y Shin, Suryakanth R Gurudu, R Todd Hurst, Christopher B Kendall, Michael B Gotway, and Jianming Liang. Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE transactions on medical imaging*, 35(5):1299–1312, 2016.



# A practical tutorial on autoencoders for nonlinear feature fusion: Taxonomy, models, software and guidelines

David Charte  
Dept. CS and AI  
University of Granada  
Granada, España  
fdavidcl@ugr.es

Francisco Charte  
Dept. CS  
University of Jaén  
Jaén, España  
fcharte@ujaen.es

Salvador García  
Dept. CS and AI  
University of Granada  
Granada, España  
salvagl@decsai.ugr.es

María J. del Jesus  
Dept. CS  
University of Jaén  
Jaén, España  
mjjesus@ujaen.es

Francisco Herrera  
Dept. CS and AI  
University of Granada  
Granada, España  
herrera@decsai.ugr.es

**Abstract**—This is a summary of our article published in Information Fusion [1] to be part of the CAEPIA-18 Key Works.

**Index Terms**—Autoencoders, Feature fusion, Feature extraction, Representation learning, Deep Learning, Machine Learning

## I. SUMMARY

The performance of most machine learning algorithms depends on the quality of the input data, and in particular on its features. Many techniques exist which combine their information into a new feature set, with the aim of improving learned models. This new set is usually of lower dimension and contains more abstract variables. Procedures which result in new feature sets can be named after several terms: feature engineering, feature learning, representation learning, feature selection, feature extraction and feature fusion. Manifold learning algorithms, especially those based on artificial neural networks (ANNs), fall into the last category.

Autoencoders (AEs) are feedforward ANNs with a symmetric *encoder-decoder* structure (see Fig. 1), where the middle layer represents an encoding of the input data. They are trained to reconstruct their inputs onto their output layer while some restrictions prevent them from copying the data along. AE components can generally be represented as functions: an encoder  $f$  and a decoder  $g$  which map inputs  $x$  to outputs  $r$ :  $r = g(f(x))$ . The desired encoding would be  $y = f(x)$ .

Typical activation functions such as linear, binary or ReLU are of limited use in AEs, while logistic, hyperbolic tangent and SELU are more common. According to whether the dimension of their encoding is lower or higher than that of the data, AEs can be either *undercomplete* or *overcomplete*, respectively. If they have just one hidden layer they are called *shallow*, and otherwise they are considered *deep*.

A taxonomy of the main variants of AEs has been proposed according to the properties of the inferred model:

This work is supported by the Spanish National Research Projects TIN2015-68454-R and TIN2014-57251-P, and Project BigDaP-TOOLS - Ayudas Fundación BBVA a Equipos de Investigación Científica 2016.

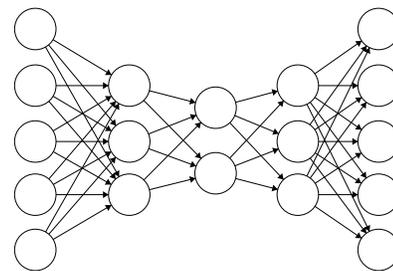


Fig. 1. A possible neural architecture for an autoencoder.

- Lower dimensionality
  - Basic [2]: the basis for most autoencoders, a symmetric feedforward ANN with a distance between the outputs and the inputs as the objective function, trainable with stochastic variants of gradient descent (SGD, AdaGrad, RMSProp, Adam...). Training can be done layer by layer in a stacked fashion.
  - Convolutional [3]: layers in this variant are convolutional, which explicitly consider a 2-dimensional structure for processing images.
  - LSTM-based [4]: models sequential data by placing Long-Short-Term Memory units as encoders and decoders.
- Regularization
  - Sparse [5]: introduces a penalty term for encodings with many activations, thus resulting in a low activation average. The Kullback-Leibler divergence can be used to attract the AE to the desired average activation value.
  - Contractive [6]: achieves local invariance to changes in many directions around the training samples by adding a penalty term based on the Frobenius norm of the Jacobian matrix of the encoder.
- Noise tolerance
  - Denoising [7]: its generated features are less sensitive to noise by training with corrupted versions of

input data.

- Robust [8]: uses a special loss function, correntropy, in order to build more robust features. Correntropy measures the probability density that two events are equal, and is less affected by outliers than other distance metrics.
- Generative model
  - Variational [9]: applies a variational Bayesian approach to encoding, assuming a latent, unobserved random variable generates the observations. It tries to approximate the distribution of the latent variable given the data.
  - Adversarial [10]: brings adversarial learning to AEs, simultaneously training a discriminator and a generator (the encoder), each competing with the other.

AEs are also the inspiration for other, more complex, neural structures. For example, autoencoder trees which involve decision trees, dual-autoencoders which learn two latent representations, and recursive AEs which introduce more pieces of input as the model deepens.

AEs can be related to the wide range of existing feature fusion methods: in the linear case, they are equivalent to PCA when linear activations and mean squared error loss function are used. As a consequence, they can be seen as generalizations of PCA which allow nonlinearities and other objective functions. They are more easily applicable than Kernel PCA since in that case the choice of kernel highly alters the behavior of the model. Other nonlinear approaches such as Isomap and Locally Linear Embedding can be compared to the contractive AE, as they attempt to preserve the local structure of the data. Restricted Boltzmann Machines are alternatives to AEs for greedy layer-wise initialization, but their models are hard to simulate than those of AEs.

The usual purpose of AEs is performing feature fusion in order to improve classification and regression performance, and to facilitate other unsupervised tasks which can be hard in high-dimensional scenarios, such as clustering. Most applications of AEs can be summarized in the following categories:

- Classification: reducing or transforming the training data in order to achieve better performance in a classifier.
- Data compression: training AEs for specific types of data to learn efficient compressions.
- Detection of abnormal patterns: identification of discordant instances by analyzing generated encodings.
- Hashing: summarizing input data onto a binary vector for faster search.
- Visualization: projecting data onto 2 or 3 dimensions with an AE for graphical representation.
- Other purposes: reconstruction of deteriorated images, noise reduction in automatic speech recognition, curation of biological databases, tagging digital resources.

In [1] we propose some guidelines which can help when designing AEs for different tasks. The following is an overview of these:

- Architecture: a starting point is choosing the desired length of the encoding and the type of units for the neural structure.
- Activations and loss function: sigmoid-like functions generally work well in the encoding layer. Place linear or ReLU at the output when using mean squared error, or logistic activation when using cross-entropy error.
- Regularizations: can be used according to the desired properties in the encoding. Weight decay can prevent overfitting, sparsity can be useful in many scenarios and contraction can find a lower-dimensional manifold.

The main software libraries and frameworks which allow for the construction and training of AEs are Tensorflow, Caffe, Torch, MXNet, and Keras. Software pieces which specifically implement AEs are packages Autoencoder and SAENET of the CRAN repository, H2O and yadlt for Python.

A case study is provided in [1] with the well known MNIST handwritten digits dataset, covering several adjustable parameters such as the encoding length, the optimization algorithm, activation functions and some of the predominant AE variants.

## REFERENCES

- [1] D. Charte, F. Charte, S. García, M. J. del Jesus, and F. Herrera, “A practical tutorial on autoencoders for nonlinear feature fusion: Taxonomy, models, software and guidelines,” *Information Fusion*, vol. 44, pp. 78–96, 2018.
- [2] H. Bourlard and Y. Kamp, “Auto-association by multilayer perceptrons and singular value decomposition,” *Biological cybernetics*, vol. 59, no. 4, pp. 291–294, 1988.
- [3] J. Masci, U. Meier, D. Cireşan, and J. Schmidhuber, “Stacked convolutional auto-encoders for hierarchical feature extraction,” in *Artificial Neural Networks and Machine Learning – ICANN 2011: 21st International Conference on Artificial Neural Networks, Espoo, Finland, June 14-17, 2011, Proceedings, Part I*, T. Honkela, W. Duch, M. Girolami, and S. Kaski, Eds. Springer Berlin Heidelberg, 2011, pp. 52–59.
- [4] N. Srivastava, E. Mansimov, and R. Salakhudinov, “Unsupervised learning of video representations using LSTMs,” in *International Conference on Machine Learning*, 2015, pp. 843–852.
- [5] A. Ng, “Sparse autoencoder,” *CS294A Lecture notes*, vol. 72, no. 2011, pp. 1–19, 2011.
- [6] S. Rifai, Y. Bengio, P. Vincent, and Y. N. Dauphin, “A generative process for sampling contractive auto-encoders,” in *Proceedings of the 29th International Conference on Machine Learning*, ser. ICML’12. Omnipress, 2012, pp. 1811–1818.
- [7] P. Vincent, H. Larochelle, Y. Bengio, and P.-A. Manzagol, “Extracting and composing robust features with denoising autoencoders,” in *Proceedings of the 25th International Conference on Machine Learning*, ser. ICML’08. ACM, 2008, pp. 1096–1103.
- [8] Y. Qi, Y. Wang, X. Zheng, and Z. Wu, “Robust feature learning by stacked autoencoder with maximum correntropy criterion,” in *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2014, pp. 6716–6720.
- [9] D. P. Kingma and M. Welling, “Auto-encoding variational bayes,” *arXiv preprint arXiv:1312.6114*, 2013.
- [10] A. Makhzani, J. Shlens, N. Jaitly, I. Goodfellow, and B. Frey, “Adversarial autoencoders,” *arXiv preprint arXiv:1511.05644*, 2015.

# I Workshop en Ciencia de Datos en Redes Sociales (CidReS 2018)

DAVID CAMACHO  
MARÍA VICTORIA LUZÓN

**Secretaría Técnica:**  
EUGENIO MARTÍNEZ CÁMARA





---

# **I Workshop en Ciencia de Datos en Redes Sociales (CidReS 2018)**

## **SESIÓN 1**







# Using Facebook Reactions to Recognize Emotion in Political Domain

Flor Miriam Plaza-del-Arco, Salud María Jiménez-Zafra,  
 María-Teresa Martín-Valdivia, L. Alfonso Ureña-López  
*Department of Computer Science, Advanced Studies Center in ICT (CEATIC)*  
*Universidad de Jaén*  
 Campus las Lagunillas, 23071, Jaén, Spain  
 fmplaza@ujaen.es, sjzafra@ujaen.es, maite@ujaen.es, laurena@ujaen.es

**Abstract**—Opinion Mining and Emotion Mining are part of the Sentiment Analysis area, but they have different objectives. Opinion Mining is concerned with the study of opinions expressed in texts and its basic task is polarity detection, whereas Emotion Mining is related to the study of emotions and its basic task is emotion recognition. Polarity detection is usually a binary classification task with outputs such as *positive* vs. *negative* or *like* vs. *dislike*, while emotion recognition aims to enable computers recognize and express emotions. In this paper we focus on Spanish emotion classification. We first compile a corpus from Facebook using the reactions in comments and posts in order to label different emotions. Then we apply a basic machine-learning approach and two lexicon-based approaches, one using a Spanish version of the NRC Emotion Lexicon (Emolex) and another adapting WordNet-Affect to Spanish. The results demonstrate the difficulty of the task and show some interesting features in the lexicon approaches.

**Index Terms**—Emotion Mining, Natural Language Processing, Social media, Facebook reactions, lexicon, machine learning, Emolex, WordNet-Affect

## I. INTRODUCTION

Emotion classification is a new task that combines several disciplines including Artificial Intelligence and Psychology, although Natural Language Processing is perhaps the most challenging area [1].

Recognize emotions in texts is becoming more and more important due to the fact that it can provide substantial benefits for different sectors [2], for instance detecting signs of depression [3], identifying cases of cyber-bullying [4] or contributing to improve student motivation and performance [5].

On the other hand, social media have changed the way people interact, as they allow the creation and exchange of user-generated content. Social networks are one of the main social media sites in which subjective information is published. Not only this social emotions are expressed in social media networks like Twitter or Facebook but also are said to have a high impact on public discourse and communication in society [6].

In this paper we focus on emotion recognition in Spanish over Facebook posts and comments for several reasons:

- (i) Emotion mining is a difficult task and the current results are not as accurate as those of polarity classification due to its multi-label nature.
- (ii) Most of the existing studies are focused on English, but the presence of other languages on the web is greater every day. Spanish is the second most spoken language in the world and in the two main social networks: Facebook and Twitter.<sup>1</sup>
- (iii) There are few resources and corpora for emotion recognition in Spanish.
- (iv) Facebook is currently the most popular social network. It has approximately 2,167 million of users according to a study of *statista*<sup>2</sup>.

Therefore, in order to advance in emotion recognition in Spanish, we present a corpus of posts and comments in the political domain which was compiled from the Facebook page *DignidadResponsabilidad*<sup>3</sup>, a Spanish popular page about politics. We first propose a basic Machine Learning (ML) approach to classify emotions in Spanish using the Support Vector Machine (SVM). Then we compare the ML method with two lexicon-based approaches. The first one uses the Emolex Spanish lexicon [7] and the second one proposes adapting the well-known WordNet-Affect (WNA) resource [8] to Spanish.

The rest of the paper is organized as follows: Section 2 describes some related studies; Corpora, ML and lexicon-based approaches are presented in Section 3; Section 4 shows the results and discussion, and finally, our conclusions are presented in Section 5.

## II. BACKGROUND

Emotion recognition is becoming very popular, and some of the main conferences dealing with data and text mining and evaluation are currently including workshops and share tasks

<sup>1</sup>[http://www.cervantes.es/sobre\\_instituto\\_cervantes/prensa/2017/noticias/Presentaci%C3%B3n-Anuario-2017.htm](http://www.cervantes.es/sobre_instituto_cervantes/prensa/2017/noticias/Presentaci%C3%B3n-Anuario-2017.htm)

<sup>2</sup><https://www.statista.com/statistics/272014/global-social-networks-ranked-by-number-of-users>

<sup>3</sup>[https://www.facebook.com/DignidadResponsabilidad/?ref=br\\_rs/](https://www.facebook.com/DignidadResponsabilidad/?ref=br_rs/)

related to it. These include Semantic Evaluation (SemEval) [9], Computational Approaches to Subjectivity and Sentiment Analysis (WASSA)<sup>4</sup> and workshops on Computational Modeling of People's opinions, personality and emotions in Social Media (PEOPLE)<sup>5</sup>.

Scientific studies on classification of human emotions date back to 1960s. From a psychological perspective, an emotion is basic only if it does not contain another emotion; that is, if it represents an atomic, irreducible psychological construct [10]. Moreover, emotions can be recognized by humans all over the world regardless of their race, culture, and language. Many theorists have proposed sets of emotions that tend to be basic ones. While psychologists do not agree on what model describes more accurately the set of basic emotions, the most widely used in computer research is the one proposed by Ekman [11], with 6 emotions (anger, disgust, fear, joy, sadness and surprise) [12]. There are different works that use this model to create labeled emotions corpora or to identify emotions in the text. For example, Mohammad [13] created a corpus of emotional tweets from Twitter (TEC)<sup>6</sup>. He targeted the six basic emotions proposed by Ekman and chose six hashtags addressing these emotions to search for appropriate tweets. Another work is the one proposed by Strapparava and Mihalcea [14]. They describe the construction of a large data set annotated for six basic emotions and propose and evaluate several knowledge-based and corpus based methods for the automatic identification of these emotions in text.

Emotion mining techniques can be classified into two categories: lexicon based approaches and machine learning approaches [15]. The first one is based on lexical resources such as lexicons, bags of words or ontologies. The second approach applies ML algorithms based on linguistic features.

Several interesting studies have explored emotion recognition and most of them deal with English texts [16]. Many of these studies focus on evaluating information from social networks since they are appropriate places to share one's feelings easily and widely. Recognize automatically emotions in social media texts can provide the tools to researchers, and citizens in general, to monitor the pulse of the society towards specific topics of interest, a task traditionally accomplished only through opinion polls, which are costly and time consuming to conduct, and therefore frequently limited to small sample sizes. Most of the works have explored emotions from Twitter and different machine learning techniques [17]. For example, Purver and Battersby [18] exploit both emoticons and Twitter hashtags for emotion recognition, Mohammad and Kiritchenko [19] use hashtags to capture fine emotion categories from tweets and Bollen et al. [20] analyze emotions of all tweets in a specific time frame using a psychometric test, names "Profile of Mood States" (POMS).

<sup>4</sup><https://wt-public.emm4u.eu/wassa2018/>

<sup>5</sup><https://peopleswksh.github.io/index.html>

<sup>6</sup><http://saifmohammad.com/WebPages/lexicons.html>

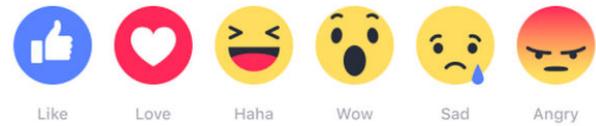


Fig. 1. Facebook reactions.

Regarding Facebook, there are few papers centered on emotion recognition, partly because it is difficult to get a labeled dataset for such a purpose. However, since February 2016 Facebook users have been able to express specific emotions in response to a given post or comment due to the newly introduced reaction feature. It has been observed that this new feature helps Facebook to know much more about its users and exploit this information for targeted advertising [21]. Krebs et al. [22] collected posts and their reactions from Facebook pages and constructed a dataset. They combine sentiment analysis and emotion mining techniques with neural network architectures in order to predict the distribution of reactions on Facebook posts. Moreover, they present a simple visualization environment. Pool and Nissim [23] take advantage of the Facebook reaction feature in a distant supervised fashion in order to train an SVM classifier for emotion detection, using several feature combinations and combining different Facebook pages. In our paper we follow the same idea to exploit the Facebook reaction feature, but applied to Spanish posts and comments.

### III. METHODOLOGY

In this section, we describe the process for generating the corpora and the approaches applied.

#### A. Corpus generation

In February 2016, Facebook made a more explicit reaction feature available world-wide. *Reactions* is an extension of the *Like* button which gives people more ways to express themselves and share their reaction to a post or comment. The collection of reactions include *Like*, *Love*, *Haha*, *Wow*, *Sad* and *Angry* (Figure 1).

We collected Facebook comments and posts with their corresponding reactions from a public page using the Facebook graph API<sup>7</sup>. We chose the Facebook page DignidadResponsabilidad<sup>8</sup>. It is a page that contains Spanish post and comments in the political domain. Currently it has 140,223 followers and 156,891 people like it. We downloaded the available posts and comments of this page from February 2016 to December 2017, recovering also the counts of reactions for each post and comment. The posts and comments are saved following a JSON structure. In the Figure 2 it can be seen an example.

<sup>7</sup><https://developers.facebook.com/docs/graph-api/>

<sup>8</sup>[https://www.facebook.com/DignidadResponsabilidad/?ref=br\\_rs/](https://www.facebook.com/DignidadResponsabilidad/?ref=br_rs/)



```
{
  {
    "status_id": "120857194649240_1259461114122170"
    "message": "REAL COMO LA VIDA MISMA Los Morancos y
    su particular versión sobre el juicio de Urmangarín."
    "status_published": "2017-03-12 08:31:59"
    "num_reactions": 88
    "num_comments": 3
    "num_shares": 32
    "num_likes": 74
    "num_loves": 4
    "num_wows": 0
    "num_hahas": 7
    "num_sads": 3
    "num_angrys": 0
  }
}
```

Fig. 2. Sample of resulting JSON file.

In order to assign the general emotion for the post or comment, we chose the majority reaction. In addition, we did not consider the reaction *Like* because it is the most generic that users tend to use and it would be biased. Finally, we obtained three different corpus: Post corpus (PC) with 1071 posts, Comment corpus (CC) that contains 1036 responses to the posts, and Post and comment corpus (PCC) with the union of the PC and CC, that is, 2107 samples in total. Statistics of Facebook reactions in these corpora can be observed in Table I. For the experimentation, we randomly partitioned the corpora into equally sized for training and testing (50% train and 50% test).

TABLE I  
NUMBER OF DIFFERENT FACEBOOK REACTIONS IN PC AND CC

Facebook reaction	post	comment
Angry	747	171
Haha	225	359
Love	68	317
Wow	13	85
Sad	18	104
Total	1071	1036

### B. Machine learning approach

In order to evaluate the ML method, we chose scikit learn package<sup>9</sup> of python and we applied as baseline the SVM algorithm. We selected the SVM formulation, known as C-SVC, the value of the C parameter was 1.0 and the kernel chosen was the linear. As has been mentioned before, 50% of the corpora was used for training and the remaining 50% for testing. Each document was represented as a vector of unigrams using the TF-IDF weighting scheme, but previously the following preprocessing step was carried out. The documents were tokenized using NLTK TweetTokenizer<sup>10</sup>, stopwords were removed, stemming was performed using NLTK

<sup>9</sup><http://scikit-learn.org/stable/>

<sup>10</sup><http://www.nltk.org/api/nltk.tokenize.html>

Snowball stemmer for Spanish<sup>11</sup> and all letters were converted to lower-case.

### C. Lexicon-based approach

In order to evaluate the lexicon-based approach for emotion classification we followed two different methods. Firstly, we applied the NRC Spanish Emotion Lexicon [7] and secondly, we adapted the English WNA Lexicon [8] to Spanish.

The Emolex Spanish Emotion lexicon is a version of the NRC Emotion Lexicon (Emolex)<sup>12</sup> that was built by translating English emotional terms into Spanish using Google Translator. In order to classify emotions the documents were tokenized using NLTK TweetTokenizer, stopwords were removed, and all letters were converted to lower-case. The emotion labels (EL) of the terms present in the text are obtained by identifying the presence of these terms in the Emolex lexicon. We map these labels into Facebook reactions (Table II) and then assign 1 as confidence value (CV). Additionally, we identify the emojis present in the text using the faces of an emoji lexicon<sup>13</sup>, we map them into Facebook reactions and we assign 1 as CV. Once the EL and CV of each word/emoji have been obtained, the general emotion is calculated in the following way: For each EL identified, we add the CV of the tokens that belong to it and we assign the EL with the highest sum to the text. In the case of two or more emotions having the same sum of CV or no EL being detected, we assign the most frequent EL, previously computed in the corresponding training corpus.

TABLE II  
MAPPING OF THE GENERAL EMOTION OF EMOLEX TO FACEBOOK REACTIONS

Facebook reaction	Emolex emotion
Sad	Sadness
Angry	Anger
Wow	Surprise
Love	
Haha	Joy

On the other hand, WNA is a linguistic resource that was built starting from WordNet Domains [24] through the selection and labeling of the synsets representing affective concepts. In particular, one or more affective labels are assigned to a number of WordNet synsets. This resource is focused on English, but we tackle Spanish texts. Therefore, we need to develop a method for obtaining affect labels for Spanish terms and obtaining their corresponding synsets with the aim of discovering the associated emotion in WNA. For this, we use the lexical disambiguator Babelfy<sup>14</sup> [25] to obtain the corresponding *BabelNet synset id* for each term in the

<sup>11</sup><http://www.nltk.org/api/nltk.stem.html>

<sup>12</sup><http://saifmohammad.com/WebPages/NRC-Emotion-Lexicon.htm>

<sup>13</sup><https://github.com/erunion/emoji-lexicon>

<sup>14</sup>Babelfy is based on the BabelNet multilingual semantic network and performs disambiguation and entity linking.

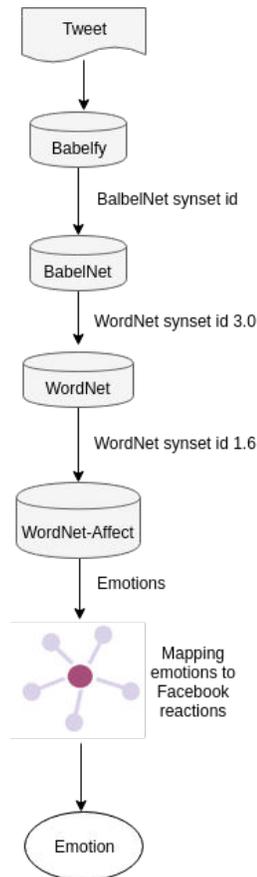


Fig. 3. Pipeline for adapting WNA to Spanish.

Spanish text. BalbelNet [26]<sup>15</sup> is a semantic network which is connected through synsets with WordNet. Using the BabelNet API we can obtain a correspondence between the *BalbelNet synset id* and the *WordNet synset id*. WNA includes a subset of appropriate synsets of WordNet 1.6 to represent affective concepts. However, the *WordNet synsets id* obtained with BabelNet API corresponds to the 3.0 version of WordNet. Therefore, we obtain the equivalent synset to the 3.0 version in the 1.6 version, and using the synset of the 1.6 version of WordNet we take the associated emotion and confident value from WNA. In Figure 3 it can be seen a diagram of the process described above.

WNA provides a set of emotional words organized in a tree. The leaf nodes represent specific emotions that are grouped into general categories (parent nodes). For example, *anger*, *hate* and *dislike* belong to the overall emotion *general-dislike*. However, WNA emotions are not the same as Facebook reactions. For this reason, each overall emotion of WNA has been mapped with Facebook reactions (Table III). The EL of the terms present in the text and their CV are obtained

<sup>15</sup>BabelNet is a multilingual encyclopedic dictionary, with lexicographic and encyclopedic coverage of terms in 271 languages, and a semantic network which connects concepts and named entities, made up of more than 13 million entries

using WNAffect python package<sup>16</sup>. These EL are mapped into Facebook reactions following Table III. Moreover, we identify the emojis present in the text using the faces of an emoji lexicon, we map them into Facebook reactions and we assign 1 as CV. Once the EL and CV of each word/emoji have been obtained, the overall emotion is computed as follows: For each EL identified, we add the CV of the tokens that belong to it and we assign the EL with the highest sum to the whole text. In the case of two or more emotions having the same sum of CV or no EL being detected, we assign the most frequent EL, previously computed in the corresponding training corpus.

TABLE III  
MAPPING OF THE GENERAL EMOTION OF WORDNET-AFFECT TO FACEBOOK REACTIONS

Facebook reaction	WNA emotion
Sad	apathy, neutral-unconcern, pensiveness, gravity, humility, compassion, despair, sadness
Angry	ambiguous-fear, ambiguous-expectation, ingratitude, shame, general-dislike
Wow	thing, ambiguous-agitation, surprise, positive-fear, positive-expectation, daze, anxiety, negative-fear
Love	gratitude, fearlessness, affection, self-pride, enthusiasm, positive-hope, calmness, love, liking
Haha	levity, joy

#### IV. RESULTS AND DISCUSSION

Table 2, 3 and 4 show the results obtained over the three datasets on the test sets (PC, CC and PCC). We can observe that the ML approach obtains better results as usual and expected. However, the results among the emotions are quite biased mainly due to the unbalance nature of the different corpora. Thus, it seems clear that we need to collect a corpus including enough samples for each emotion in order to our system can learn all of them.

Regarding the lexicon approaches, both methods achieve very low results. In addition, the majority emotion for each corpus determines the best result in this emotion because when our system does not recognize any emotion, we assign the majority one. For example, the *angry* emotion is the majority class in the PC and, thus, the results in this corpus are also biased to this emotion. For this reason, we performed other experiments, taking into account only the texts where our method recognizes one emotion, and neglecting the posts and comments with No-Emotion detected (WNA-NE and Emolex-NE). The results are very similar to the previous ones, but in this case it is interesting to note that WNA finds very few emotion words and, thus, the recall is very low, while with Emolex the texts detected with emotion almost reaches 80%. Specifically, WNA recognizes 67, 67 and 134 texts with emotions and Emolex

<sup>16</sup><https://github.com/clemtoy/WNAffect>



500, 327 and 827 for the PC, CC and PCC, respectively. Taking into account that the total number of texts in each test corpus is 534, 516 and 1050, the texts classified with emotion represent 13%, 13% and 13% for WNA and 94%, 63% and 79% for Emolex, respectively.

## V. CONCLUSION

In conclusion, emotion classification is a hard task that needs not only a deeper study but also specific linguistic resources in order to tackle the problem. Our next study will focus on collecting a larger and more balanced emotion corpus including others domains and studying the combination of different resources in order to generate a quality lexicon. In addition, we will compare the results obtained with English and Spanish corpora. Also, we plan to continue working on emotion recognition in Spanish because we have observed that the work in this language is very scarce, although it is the second most spoken language in the world and in the two main social networks: Facebook and Twitter.

It could be interesting to explore more affect lexicons because they provide prior information about the type and strength of emotion carried by each word of the text. Actually, in WASSA-2017 Shared Task on Emotion Intensity it was demonstrated that using features from affect lexicons is beneficial for emotion mining tasks [17].

Finally, this system could be used to measure the satisfaction of citizens with politicians that could be very useful, for example, to predict results in a political campaign based on the emotions transmitted by users in posts and comments of the Facebook page *Dignidad y Responsabilidad*<sup>17</sup>.

## ACKNOWLEDGEMENTS

This work has been partially supported by a grant from the Ministerio de Educación Cultura y Deporte (MECD - scholarship FPU014/00983), Fondo Europeo de Desarrollo Regional (FEDER) and REDES project (TIN2015-65136-C2-1-R) from the Spanish Government.

## REFERENCES

- [1] R. W. Picard *et al.*, “Affective computing,” 1995.
- [2] L. Canales, C. Strapparava, E. Boldrini, and P. Martinez-Barco, “Innovative semi-automatic methodology to annotate emotional corpora,” *PEOPLES 2016*, p. 91, 2016.
- [3] C. Cherry, S. M. Mohammad, and B. De Bruijn, “Binary classifiers and latent sequence models for emotion detection in suicide notes,” *Biomedical informatics insights*, vol. 5, no. Suppl 1, p. 147, 2012.
- [4] M. Dadvar, D. Trieschnigg, R. Ordelman, and F. de Jong, “Improving cyberbullying detection with user context.” in *ECIR*. Springer, 2013, pp. 693–696.
- [5] C. Suero Montero and J. Suhonen, “Emotion analysis meets learning analytics: online learner profiling beyond numerical data,” in *Proceedings of the 14th Koli calling international conference on computing education research*. ACM, 2014, pp. 165–169.
- [6] S. Stieglitz and L. Dang-Xuan, “Emotions and information diffusion in social media—sentiment of microblogs and sharing behavior,” *Journal of management information systems*, vol. 29, no. 4, pp. 217–248, 2013.
- [7] S. M. Mohammad and P. D. Turney, “Crowdsourcing a word-emotion association lexicon,” vol. 29, no. 3, pp. 436–465, 2013.
- [8] C. Strapparava and A. Valitutti, “Wordnet affect: an affective extension of wordnet.” in *LREC*, vol. 4, 2004, pp. 1083–1086.
- [9] S. M. Mohammad, F. Bravo-Marquez, M. Salameh, and S. Kiritchenko, “Semeval-2018 Task 1: Affect in tweets,” in *Proceedings of International Workshop on Semantic Evaluation (SemEval-2018)*, New Orleans, LA, USA, 2018.
- [10] A. Celeghin, M. Diano, A. Bagnis, M. Viola, and M. Tamietto, “Basic emotions in human neuroscience: neuroimaging and beyond,” *Frontiers in Psychology*, vol. 8, p. 1432, 2017.
- [11] P. Ekman, “An argument for basic emotions,” *Cognition & emotion*, vol. 6, no. 3-4, pp. 169–200, 1992.
- [12] A. Gholipour Shahraki, “Emotion mining from text,” 2015.
- [13] S. M. Mohammad, “# emotional tweets,” in *Proceedings of the First Joint Conference on Lexical and Computational Semantics-Volume 1: Proceedings of the main conference and the shared task, and Volume 2: Proceedings of the Sixth International Workshop on Semantic Evaluation*. Association for Computational Linguistics, 2012, pp. 246–255.
- [14] C. Strapparava and R. Mihalcea, “Learning to identify emotions in text,” in *Proceedings of the 2008 ACM symposium on Applied computing*. ACM, 2008, pp. 1556–1560.
- [15] E. Cambria, “Affective computing and sentiment analysis,” *IEEE Intelligent Systems*, vol. 31, no. 2, pp. 102–107, 2016.
- [16] A. Yadollahi, A. G. Shahraki, and O. R. Zaiane, “Current state of text sentiment analysis from opinion to emotion mining,” *ACM Comput. Surv.*, vol. 50, no. 2, pp. 25:1–25:33, May 2017. [Online]. Available: <http://doi.acm.org/10.1145/3057270>
- [17] S. M. Mohammad and F. Bravo-Marquez, “Wassa-2017 shared task on emotion intensity,” *arXiv preprint arXiv:1708.03700*, 2017.

<sup>17</sup>[https://www.facebook.com/Dignidad y Responsabilidad/?ref=br\\_rs/](https://www.facebook.com/Dignidad y Responsabilidad/?ref=br_rs/)

TABLE IV  
RESULTS ON THE TEST SET OF PC

Approach	angry			haha			love			wow			sad		
	prec	rec	f	prec	rec	f	prec	rec	f	prec	rec	f	prec	rec	f
SVM	0.71	0.97	0.81	0.35	0.05	0.09	0	0	0	0	0	0	0	0	0
WNA	0.7	0.9	0.79	0.25	0.02	0.03	0.1	0.06	0.07	0.07	0.17	0.1	0	0	0
Emolex	0.67	0.67	0.67	0.16	0.07	0.1	0	0	0	0	0	0	0	0	0
WNA-NE	0.6	0.2	0.3	0.25	0.17	0.2	0.1	0.33	0.15	0.07	0.05	0.12	0	0	0
Emolex-NE	0.7	0.66	0.68	0.16	0.08	0.11	0	0	0	0	0	0	0	0	0

TABLE V  
RESULTS ON THE TEST SET OF CC

Approach	angry			haha			love			wow			sad		
	prec	rec	f	prec	rec	f	prec	rec	f	prec	rec	f	prec	rec	f
SVM	0.3	0.21	0.25	0.38	0.46	0.42	0.38	0.51	0.43	0	0	0	0.08	0.02	0.03
WNA	0.24	0.06	0.1	0.36	0.91	0.51	0.37	0.03	0.05	0	0	0	0.13	0.04	0.06
Emolex	0.16	0.21	0.18	0.4	0.71	0.51	0	0	0	0	0	0	0.16	0.25	0.2
WNA-NE	0.24	0.45	0.31	0.29	0.11	0.15	0.36	0.15	0.21	0	0	0	0.13	0.29	0.18
Emolex-NE	0.16	0.35	0.22	0.36	0.46	0.40	0	0	0	0	0	0	0.16	0.34	0.22

TABLE VI  
RESULTS ON THE TEST SET OF PCC

Approach	angry			haha			love			wow			sad		
	prec	rec	f	prec	rec	f	prec	rec	f	prec	rec	f	prec	rec	f
SVM	0.55	0.78	0.65	0.4	0.35	0.37	0.31	0.21	0.25	0	0	0	0	0	0
WNA	0.43	0.91	0.59	0.27	0.01	0.03	0.17	0.03	0.05	0.04	0.02	0.03	0.09	0.03	0.05
Emolex	0.43	0.66	0.52	0.27	0.13	0.18	0	0	0	0	0	0	0.07	0.21	0.10
WNA-NE	0.37	0.25	0.3	0.27	0.13	0.17	0.17	0.15	0.16	0.04	0.2	0.06	0.09	0.22	0.13
Emolex-NE	0.54	0.63	0.58	0.27	0.2	0.23	0	0	0	0	0	0	0.07	0.28	0.11

- [18] M. Purver and S. Battersby, "Experimenting with distant supervision for emotion classification," in *Proceedings of the 13th Conference of the European Chapter of the Association for Computational Linguistics*. Association for Computational Linguistics, 2012, pp. 482–491.
- [19] S. M. Mohammad and S. Kiritchenko, "Using hashtags to capture fine emotion categories from tweets," *Computational Intelligence*, vol. 31, no. 2, pp. 301–326, 2015.
- [20] J. Bollen, H. Mao, and X. Zeng, "Twitter mood predicts the stock market," *Journal of computational science*, vol. 2, no. 1, pp. 1–8, 2011.
- [21] L. Stinson, "Facebook reactions, the totally redesigned like button, is here," *Wired*, February 24th, 2016.
- [22] F. Krebs, B. Lubascher, T. Moers, P. Schaap, and G. Spanakis, "Social emotion mining techniques for facebook posts reaction prediction," *arXiv preprint arXiv:1712.03249*, 2017.
- [23] C. Pool and M. Nissim, "Distant supervision for emotion detection using facebook reactions," *arXiv preprint arXiv:1611.02988*, 2016.
- [24] B. Magnini and G. Cavaglia, "Integrating subject field codes into wordnet," in *LREC*, 2000, pp. 1413–1418.
- [25] A. Moro, A. Raganato, and R. Navigli, "Entity linking meets word sense disambiguation: a unified approach," *Transactions of the Association for Computational Linguistics*, vol. 2, pp. 231–244, 2014.
- [26] R. Navigli and S. P. Ponzetto, "Babelnet: The automatic construction, evaluation and application of a wide-coverage multilingual semantic network," *Artificial Intelligence*, vol. 193, pp. 217–250, 2012.

# Visualización avanzada de datos de Twitter para su análisis como canal de comunicación

## Caso del mercado maduro de las bodegas con Denominación de Origen Calificada Rioja

Carmen Zarco

Departamento de Investigación de Mercados  
Universidad Internacional de La Rioja  
Logroño, ESPAÑA  
e-mail: [carmen.zarco@unir.net](mailto:carmen.zarco@unir.net)

Oscar Cordon

Instituto Andaluz Interuniversitario de Ciencia de Datos e  
Inteligencia Computacional (DaSCI)  
Universidad de Granada. Granada, ESPAÑA  
e-mail: [ocordon@decsai.ugr.es](mailto:ocordon@decsai.ugr.es)

**Resumen**— Las organizaciones se enfrentan a nuevas oportunidades y desafíos planteados por las redes sociales. Las empresas están evaluando el valor potencial de este fenómeno social para justificar la inversión de recursos en su adopción. Los Medios Sociales facilitan la distribución de información, referencias y reseñas electrónicas de boca en boca a través de redes sociales virtuales, foros de discusión, blogs y microblogs, incluido Twitter. El objetivo de este trabajo es identificar el modelo de comunicación desarrollado por las bodegas con Denominación de Origen Calificada Rioja en Twitter. Pretendemos conocer dicho modelo de comunicación desde una visión global y relacional, estudiando las características comunes y diferenciales de las distintas bodegas en su estrategia de comunicación en esta red social. Para ello, usaremos datos de presencia e impacto de las cuentas de Twitter de las bodegas y herramientas de visualización de datos avanzadas basadas en técnicas de Análisis de Redes Sociales.

**Palabras clave**— Twitter; Comunicación; Visualización de Datos; Análisis de Redes Sociales; Bodegas DOCa Rioja.

### I. INTRODUCCION

Los Medios Sociales se han convertido en una importante plataforma de medios de comunicación que conecta a un tercio de la población [1]. Se ha producido una redistribución de los presupuestos destinados a la comunicación en las organizaciones a medida que los anunciantes se han alejado de los medios tradicionales invirtiendo mayores recursos en publicidad digital y redes sociales. Se estima el 58% de las marcas registradas en Twitter tienen más de 100.000 seguidores cada una [2]. El surgimiento de estas plataformas de redes sociales y su creciente adopción por parte de los clientes han precipitado un cambio de paradigma, alterando significativamente la forma en que los clientes se comunican e interactúan entre sí y con las empresas.

El uso de Twitter como plataforma digital global de interacción social no admite discusión alguna. Cuenta actualmente con 328 millones de usuarios activos al mes, registra 1.000 millones de visitas únicas mensuales a sitios web con acceso a la plataforma, genera más de 500 millones de tuits diarios, se encuentra disponible en más de 40 idiomas [3], [4].

Dentro de este contexto tecnológico, no es sorprendente que muchas marcas busquen nuevas e innovadoras formas de comunicarse con los consumidores. Las redes sociales como Twitter se han convertido en puntos de contacto con el cliente cada vez más populares, creando un nuevo foro para la interacción de los clientes con las marcas de vino como consecuencia de sus capacidades sociales y virales [5], [6].

En este trabajo analizaremos cómo empresas con una filosofía de tradición muy arraigada como las bodegas con Denominación de Origen Calificada (DOCa) Rioja utilizan Twitter como medio de comunicación. Pretendemos identificar el modelo desarrollado para comunicarse con sus seguidores y su impacto a través de su grado de presencia y actividad. Estudiaremos este modelo de comunicación desde una perspectiva global y relacional, descubriendo qué características comparten y diferencian a aquellas bodegas que hacen un mayor o menor uso del mismo. Para ello haremos uso de datos de presencia e impacto obtenidos de las cuentas de Twitter y de herramientas avanzadas de visualización de datos basadas en técnicas de Análisis de Redes Sociales (SNA) [7], que permitirán realizar un análisis detallado de las relaciones existentes entre las distintas organizaciones desde la perspectiva de su uso de Twitter como canal de comunicación. Nuestro objetivo es obtener representaciones visuales (*mapas*) del impacto y de las relaciones de similitud con respecto al posicionamiento de las distintas bodegas en Twitter que sean fácilmente interpretables por el analista considerando la distribución y la localización espacial de cada bodega en el mapa.

### II. MARCO TEÓRICO

El vino es un producto experiencial e implica inherentemente la socialización y construye comunidades alrededor del placer de compartir experiencias [8]. Las marcas españolas compiten para atraer y retener a los consumidores y muchas de ellas están adoptando las redes sociales para llegar a sus consumidores y comunicar su experiencia de marca, calidad y personalidad [9]. Los medios sociales y la comunicación a través de ellos mejoran ese elemento común de la apreciación y el consumo de vino creando comunidades por lo que es muy importante para aquellos involucrados en la industria del vino tener una presencia activa en las redes sociales [10].

La industria del vino está reconociendo progresivamente el papel cada vez más relevante que tienen las redes sociales como una herramienta apropiada y de gran valor para llegar a los consumidores. Las actividades de comunicación se encuentran en un estado de desarrollo evolutivo en el que continuamente surgen nuevas tendencias y las bodegas tienen la obligación de adaptarse al mismo si quieren tener éxito en sus campañas [11].

#### A. Twitter y sus usuarios

Twitter, fundada en 2006, se puede describir como una plataforma de microblogging y como una red social [12]. Tiene dos características especiales que lo diferencian de otro tipo de

plataformas similares: la limitación en el número de caracteres que se puede utilizar en cada mensaje (ahora a 280) y la forma en que se establecen las relaciones entre los usuarios. Al no requerirse una relación de amistad para interactuar, se pueden establecer relaciones con usuarios desconocidos facilitando el contacto con especialistas en temas específicos y el acceso a información actualizada relacionada con el área de interés [13].

### B. Perfil del consumidor de vino

El consumo de vino en España aumentó en 2016 después de varias décadas disminuyendo. Según el Observatorio Español del Mercado del Vino [14], la demanda de caldos registró un comportamiento positivo con una tasa de crecimiento del 2,5% al 4% hasta alcanzar un total de 9,8 millones de hectolitros. Aun así, y según los expertos, son datos muy por debajo de lo previsible para un país productor y de gran tradición vitivinícola.

Según el informe realizado por la consultora Nielsen para el Observatorio Español del Mercado del Vino [15], el perfil sociodemográfico del consumidor español de vino es fundamentalmente masculino, aunque en este momento el 43% de los consumidores son mujeres. En términos de edad, se pone de manifiesto el aumento de la proporción de consumidores aumenta con la edad. La penetración de consumidores de vino entre los más jóvenes (18 y 34 años) es del 52%, la cual aumenta en los grupos de edad entre 35 y 54 años y los superiores a 54 años hasta el 59% y 67%, respectivamente.

El vino como producto implica la socialización y construye comunidades alrededor el placer de compartir experiencias. Este intercambio y la construcción de la comunidad son procesos arraigados en redes sociales online que comparten principios similares a las relaciones humanas presenciales [16].

### C. Las bodegas y las políticas de comunicación

Investigadores y especialistas en marketing insisten en la importancia que tienen los medios sociales como un servicio de comunicación fácil y de bajo coste que proporciona una conexión inmediata con una gran cantidad de consumidores [17]. Sin embargo, estos expertos también sostienen que todavía queda un largo camino por recorrer por parte de la industria del vino para que se conviertan en una herramienta de comunicación y de marketing realmente eficiente [18]. Los expertos del sector vinícola han manifestado su inquietud por la ineficaz política de comunicación de la mayoría de bodegas españolas, pese a la notable presencia mediática que tienen los vinos [19].

Los medios tradicionales canalizan sus mensajes sobre vinos a través de la publicidad, las noticias que elaboran sus redactores y el trabajo de cada bodega para asegurarse espacios de difusión gratuita. Promueven así sus vinos, sus ideas y construyen un relato periodístico atractivo y explicativo de su actividad. Los consumidores desean participar ahora más que nunca en los procesos de comunicación. La pregunta ya no es sólo cómo llegar a ellos sino también cómo llegan ellos a las bodegas y cómo interactúan entre sí [20].

## III. METODOLOGÍA

Para llevar a cabo este análisis del uso de Twitter como canal de comunicación de las empresas con DOCa Rioja se han recopilado todos los datos relativos a su presencia en esta red de

microblogging. De las más de 590 bodegas que disponen de esta denominación, hemos comprobado que sólo 191 tienen presencia y actividad en Twitter. Uno de los hándicaps más importantes que se nos presentó fue la duplicidad de nombres de algunas bodegas que convergían en el mismo perfil dentro de la red social. De estas 191 bodegas se eliminaron tres que tenían dicha duplicidad de perfil en Twitter: Bodegas Berceo, Faustino Rivero y Bodegas Pujanza (es decir, dos bodegas distintas, generalmente de gran tamaño, empleaban la misma cuenta de Twitter en los tres casos), quedándonos finalmente con 188 bodegas/cuentas de Twitter. De cada cuenta se recopilaron datos de presencia reflejados en cuatro variables principales: *Tweets*, *Seguidores*, *Siguiendo* y *Me gusta*. La recogida de información se realizó entre los días 20 y 30 de diciembre de 2017, correspondientes a la campaña de Navidad, un periodo en el que las empresas vinícolas y los consumidores son muy activos en los medios sociales.

La base de nuestro estudio serán las técnicas de SNA para diseñar un mapa visual de las características de la comunicación en Twitter de estas bodegas con DOCa Rioja. El uso de técnicas de SNA [7], [21] ha demostrado su capacidad para generar visualizaciones esquemáticas de alta calidad de representaciones basadas en red en varios campos del conocimiento: psicología (para representar la estructura cognitiva de un tema) [22], modelado de sistemas (para analizar sistemas difusos) [23], depuración de software (para detección de bugs en sistemas multiagente) [24], optimización multiobjetivo (para visualizar la composición de las soluciones no dominadas, ayudando al decisor) [24] y cienciometría (para el análisis de grandes dominios científicos) [25], [26], entre otros.

En nuestro caso, en primer lugar diseñaremos una medida de similitud basada en los distintos indicadores de Twitter asociados a cada bodega. De esta forma, obtendremos una matriz relacional simétrica que determinará la similitud entre la estrategia de comunicación aplicada por cada par de bodegas, definiendo la estructura de la red social de bodegas correspondiente. Aplicaremos un algoritmo de poda de redes, una variante eficiente del algoritmo Pathfinder [27], sobre la matriz de similitud resultante con objeto de podar la red asociada, reduciendo las relaciones entre los modelos de comunicación definidos por las cuentas de Twitter de las bodegas para mantener solamente aquellas más significativas a nivel global. Para obtener el mapa visual, aplicaremos un algoritmo de dibujado (*layout*) de redes sociales basado en fuerzas, el algoritmo Kamada-Kawai [28], para situar los nodos de la red de modo que sus posiciones estén determinadas por las relaciones existentes.

### A. Medida de Similitud y Construcción de la Red Social

En este primer paso se consideran los datos de las cuatro variables: *Tweets*, *Seguidores*, *Siguiendo* y *Me Gusta*. Estos datos se han normalizado, con lo que cada bodega pasa a tener asociado un punto 4-dimensional en el espacio real  $[0,1]^4$ .

La medida de la similitud existente entre cada una de las bodegas de acuerdo a su política de comunicación en Twitter se define en función de la distancia Euclídea:

$$D(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^4 (x_i - y_i)^2} ,$$

lo que nos deja un cálculo como el siguiente:



$$D(\vec{x}, \vec{y}) = \sqrt{\begin{matrix} (Tweets_x - Tweets_y)^2 + \dots \\ (Siguiendo_x - Siguiendo_y)^2 + \dots \\ (Seguidores_x - Seguidores_y)^2 + \dots \\ (MeGusta_x - MeGusta_y)^2 + \dots \end{matrix}}$$

Volvemos a normalizar estos resultados localizando la distancia máxima y dividiendo las demás distancias por esta última. Después los convertimos en una medida de similitud invirtiendo esa distancia normalizada:

$$S(\vec{x}, \vec{y}) = 1 - D(\vec{x}, \vec{y}).$$

A continuación obtenemos la matriz que relaciona las distintas bodegas dependiendo del grado de similitud resultante de los datos gestionados. Es una matriz real cuadrada de dimensión 188×188, en la que no se considera la diagonal (la similitud entre una cuenta de Twitter y esa misma cuenta es máxima pero obviamente no es significativa) y que lógicamente es simétrica ( $S(\vec{x}, \vec{y}) = S(\vec{y}, \vec{x})$ ). Esa matriz define la red social asociada, una red ponderada no dirigida compuesta por 188 nodos, correspondientes a las bodegas analizadas, y  $\frac{188 \cdot 187}{2} = 17.578$  enlaces ponderados cuyo peso indica el valor de similitud entre las cuentas de Twitter de las dos bodegas que conecta.

### B. Poda de la Red Social

La visualización de redes sociales tiene varios problemas [29]: i) calidad (cuanto mayor es la red, más probabilidad hay de que existan errores en los datos; ii) complejidad: más variables, más detalle, más categorías; iii) velocidad (en muchos casos, queremos obtener resultados de nuestra red lo bastante rápido como para que pueda considerarse un proceso interactivo); y iv) análisis (¿qué orden de complejidad se requiere para los algoritmos?). En concreto, la gran dimensión que encontramos habitualmente en las redes sociales genera dificultades para obtener representaciones gráficas útiles para el análisis ya que puede provocar una sobrecarga de información para el analista, reduciendo la interpretabilidad de las representaciones gráficas que se pretende obtener.”

En la literatura existen tres alternativas predominantes en SNA para llevar a cabo esta tarea en redes ponderadas [30]:

- El primer método descarta los enlaces con pesos por debajo de un determinado umbral [31]. Este enfoque, aunque fácil de implementar, no considera la estructura intrínseca de la red subyacente. Por lo tanto, la red transformada puede no mostrar la naturaleza de la original, pudiendo obtener componentes conexas desconectadas que no se corresponden con la realidad.
- El segundo método se basa en la obtención de un árbol generador minimal a partir de la red [32]. Esto garantiza un número fijo y mínimo de enlaces (el número de nodos menos uno) pero no siempre refleja la información subyacente de un modo adecuado debido a la posibilidad de una poda excesiva.
- El tercer y último método establece restricciones en los caminos de la red y aquellos enlaces que no las satisfacen. El algoritmo Pathfinder [22] es el método usado habitualmente,

siendo conocido por sus propiedades matemáticas asociadas a la preservación de la desigualdad triangular en caminos de la red de longitud  $q$  (parámetro del algoritmo). El resultado de aplicar el método Pathfinder con parámetros  $q$  y  $r$  a una red social ponderada es una nueva red social ponderada podada denominada PFNET( $r, q$ ). Las distancias de los caminos se miden con una métrica paramétrica en la que  $r=1$  corresponde a la distancia Euclídea,  $r=2$  a la distancia cuadrática y  $r=\infty$  al peso del enlace de mayor peso. El algoritmo permite construir una secuencia de redes de complejidad decreciente aumentando el valor de  $q \in \{2, \dots, n-1\}$ . La PFNET( $r, q=1$ ) corresponde a la red original y la PFNET( $r, q=n-1$ ) está formada por el menor número posible de enlaces.

### C. Dibujado (Layout) de la Red Social

Una vez que se dispone de una PFNET o cualquier otro tipo de red social, existe una amplia batería de métodos que permiten su visualización de forma automática. Los algoritmos basados en fuerzas son los métodos más utilizados para dibujar estructuras de red en el área de las Ciencias de la Información [34]. Su propósito es ubicar los nodos de una red en un espacio bidimensional o tridimensional de forma que bien todos los enlaces o bien sean aproximadamente de igual longitud o bien se correspondan globalmente con las longitudes teóricas entre los nodos del grafo y que además se produzcan pocos cruces entre enlaces, tratando de obtener una visión lo más estética y agradable posible. Esta familia tiene a los algoritmos clásicos de Kamada-Kawai [28] y Fruchterman-Reingold [33] como sus métodos más representativos aunque existen propuestas recientes capaces de escalar hasta un millón de nodos [34].

Consideraremos el algoritmo Kamada-Kawai, que funciona bien con redes Pathfinder. Para enriquecer la visualización, usamos un código de colores para los nodos en el que el color azul refleja el valor más bajo y el rojo el valor más alto del indicador, pasando por el verde, el amarillo y el naranja que indican valores medios bajos, medios y medios altos.

## IV. VISUALIZACIÓN OBTENIDA Y ANÁLISIS DE RESULTADOS

### A. Generación del Mapa

La Figura 1 muestra la visualización resultante de aplicar la metodología de la sección III a los datos disponibles de las 188 bodegas. El parámetro de la distancia de Minkowski toma valor  $r=\infty$  ya que en estudios previos se ha comprobado que posibilita un mayor nivel de poda y por tanto una mejor visualización.

Hemos usado el algoritmo Force Atlas 2, una de las implementaciones del Kamada-Kawai de Gephi, una herramienta gráfica de libre distribución para análisis de redes muy extendida (<https://gephi.org/>). Se han usado los parámetros por defecto, cambiando el Escalado a 3.0 y considerando las opciones *Disuadir Hubs* y *Evitar el solapamiento*. Una vez obtenida la visualización de la red, se ha aplicado también el algoritmo *Ajuste de Etiquetas* de Gephi. La gradación de colores corresponde a una variable teórica *Posicionamiento en Twitter*, cuyo valor es equivalente a la media de los cuatro indicadores considerados para cada bodega.

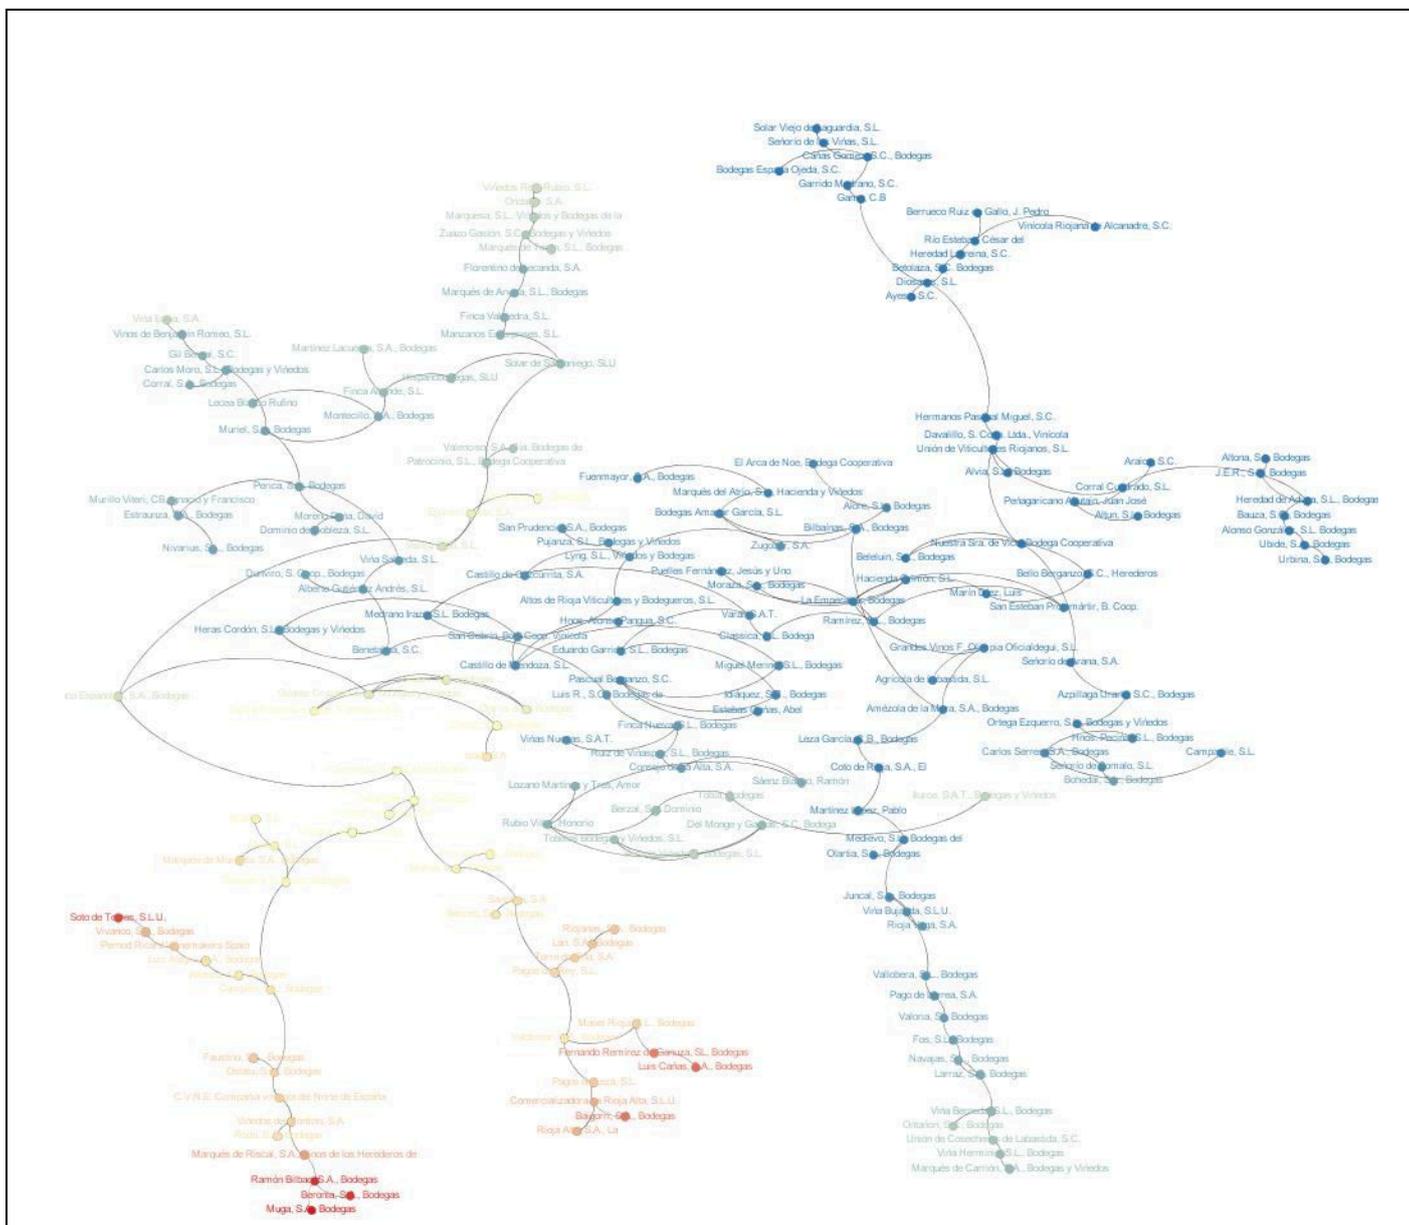


Fig. 1. Red PFNET( $r=\infty, q=n-1$ ) del modelo de comunicación de las bodegas con DOCa Rioja en Twitter (la escala de color de los nodos se basa en el posicionamiento global de las cuentas)

Esta representación visual obtenida es muy clara y permite identificar aspectos importantes de los datos analizados como las relaciones locales. Las distancias existentes entre los nodos, determinadas por el algoritmo de *layout* para hacerlas coincidir con las distancias globales de la red, representan claramente las similitudes y diferencias entre las estrategias de comunicación de las distintas bodegas. Se produce un efecto centro-periferia, habitual en este tipo de representaciones, en el que las bodegas situadas en la parte central tienen un comportamiento más similar entre sí y las posicionadas en los distintos extremos del mapa muestran políticas de comunicación muy diferenciadas con las del centro (es decir, valores significativamente distintos en los cuatro indicadores y, por tanto, en la medida de similitud) y, consecuentemente, diferentes también entre sí.

La gradación de colores nos permite observar claramente qué bodegas son las que tienen una estrategia de comunicación más activa en Twitter desde una perspectiva global de los cuatro indicadores (es decir, aquellas que presentan mayores valores en el agregado de los mismos y que por tanto tienen un tono más rojo en el mapa) y cuáles son las que la presentan menor actividad (menor valor agregado, tono más azul). Se observa fácilmente como las bodegas más cercanas entre sí presentan tonos de color (y por tanto estrategias de comunicación) similares, justificando el posicionamiento de los nodos en el mapa. Observamos como las bodegas con un modelo de comunicación más activo se sitúan en la parte inferior izquierda del mapa, siendo *Muga*, *Beronia*, *Ramón Bilbao*, *Soto de Torres*, *Baigorri*, *Luis Cañas* y *Fernando Ramírez de Ganuza* las más destacadas, por ese orden.



### B. Análisis del Mapa de Etiquetas de Posicionamiento Global

En esta sección pretendemos extraer conclusiones adicionales relacionadas con la distribución espacial de las bodegas en el mapa de modelo de comunicación en Twitter. En primer lugar se observa que en la parte superior del mapa se concentran principalmente las bodegas que apenas tienen actividad dentro de Twitter. Las bodegas que se encuentran en este grupo, como son, por ejemplo, *Solar Viejo de La Guardia*, *Señorío de las Viñas*, *Bodegas Espada Ojeda* y *Vinícola Riojana de Alcanadre*, reúnen características muy parecidas en lo que se refiere a la baja actividad en las cuatro variables analizadas y a la presencia de uno o varios ceros en las mismas. Como ejemplo, todas las bodegas citadas tienen valor cero en la variable *Me Gusta* junto con unos datos realmente bajos en las otras tres variables. Además, las dos primeras, situadas más en la periferia, presentan un cero también en *Tweets*. Nótese que el algoritmo de visualización separa claramente esta zona del resto del mapa a través de un enlace de gran longitud entre las bodegas *Hermanos Pascual Miguel* y *Diosares*, formándose un clúster con un comportamiento diferencial con respecto al centro del mapa que analizaremos a continuación.

Vemos cómo el mayor número de bodegas se concentran en el centro del mapa. Esto se debe a que la mayoría de las bodegas que utilizan Twitter tienen unos datos muy similares entre sí y con un comportamiento muy homogéneo. Como ejemplo tenemos las bodegas *Ramírez* y *La Emperatriz*, situadas en la parte más central del mapa y con valores relativamente bajos en todas las variables (*Tweets*=145, *Siguiendo*=258, *Seguidores*=309, *Me Gusta*=16 y *Tweets*=47, *Siguiendo*=176, *Seguidores*=365, *Me Gusta*=2, respectivamente), por lo que su política de comunicación en la red social se puede acabar diluyendo con el resto de empresas del sector vinícola. Este comportamiento nos confirma la inquietud que tienen las organizaciones con respecto a sus políticas de comunicación y el escaso uso que hacen de las nuevas tecnologías para realizar una política de comunicación potente, real e innovadora. Según nos acercamos tanto a la zona inferior como sobre todo a la zona izquierda del mapa, la tonalidad de color va aumentando, pasando al verde que indica un mayor valor en los indicadores. La utilidad de la información proporcionada por los enlaces a nivel local puede observarse en la bodega *Ilurce*, que aunque está situada en el centro de la parte inferior está enlazada con la rama situada a la izquierda formada por el grupo de bodegas con tonalidad verde (*Tobia*, *Berzal* y *Rubio Villar* en una rama, *Del Monge* y *Garbati* en otra, etc.). En concreto, los valores asociados a esta bodega son *Tweets*=1.418, *Siguiendo*=1.514, *Seguidores*=2.998 y *Me Gusta*=180, valores claramente superiores a los de la parte central.

Por último, vemos cómo se agrupan las bodegas en la parte baja en tres ramificaciones bien diferenciadas, cada una con una naturaleza distinta. En el grupo de la izquierda se aglutinan las bodegas que tienen un alto número de seguidores como *Ramón Bilbao* con 24.800 seguidores, *Muga* con 21.700 seguidores y *Faustino* con 10.400. Las tonalidades rojas y amarillas de esta zona nos indican que los valores del resto de variables también son altos, encontrándonos con el conjunto de bodegas con un uso más activo de la comunicación en Twitter.

En cambio, el grupo del centro incluye bodegas con los valores más altos en *Tweets*, donde destacan las bodegas

*Fernando Remírez de Ganuza*, *Luis Cañas* y *Baigorri*, con 13.000, 16.000 y 16.900 tweets respectivamente. De nuevo, las tonalidades rojas y amarillas vuelven a señalar una fuerte actividad, aunque con un modelo de comunicación distinto.

Finalmente, el tercer grupo situado a la derecha de los tres aquí analizados agrupa bodegas que tienen unos datos relativamente altos en *Tweets* y *Seguidores* pero que presentan una menor actividad desde un punto de vista global (tonos verdes, correspondientes a valores medios bajos). Dentro de este grupo destacan bodegas como *Marqués de Carrión*, *Unión de Cosecheros de Labástida*, *Ontañón* y *Viña Herminia*. Todas ellas superan holgadamente los 1.500 Tweets y cuentan con un total de *Seguidores* que oscila entre los 2.500 y 4.000, lo que da a entender que se trata de bodegas que tienen una actividad continua en comparación a la mayoría localizada en la parte central, aunque no tan intensa como pueden tener las bodegas que se sitúan más a la izquierda (en las otras dos variables, *Siguiendo* y *Me gusta*, los valores medios están en torno a 400).

### CONCLUSIONES

En este trabajo hemos analizado datos cuantitativos recopilados de la red social Twitter pertenecientes a las bodegas con DOCa Rioja. Con ello se pretendía conocer el modelo de comunicación que dichas empresas aplican en esta plataforma mediante el dibujo de un mapa que proporcionase una visualización estética de la distribución de las bodegas dependiendo del valor de las variables consideradas. El estudio realizado ha permitido desarrollar una aproximación para conocer de cerca la presencia de las bodegas y valorar el estado en el que se encuentran sus políticas de comunicación digitales, concretamente dentro de Twitter.

Una de las principales conclusiones es la escasa presencia que tienen estas organizaciones en la red social, ya que solamente 188 bodegas de un total de 591 tienen perfil en Twitter (aproximadamente un 32%) y no todas ellas tienen una actividad de comunicación activa y directa. Este hecho colisiona con el perfil del consumidor de vino y el perfil del usuario de Twitter cuyas características principales son coincidentes (hombres con edades comprendidas entre los 35 y 54 años), lo que sería razón de más para llevar a cabo una sólida política de comunicación en la red ya que es aquí donde se concentra el público objetivo al que se dirige el mercado vinícola español.

A través del mapa obtenido, hemos podido comprobar que las bodegas que acumulan un número mayor de seguidores son aquellas que tienen un nombre de marca consolidado y reconocido. No obstante ese dato no quiere decir que dichas bodegas mantengan una comunicación constante con sus seguidores a través de la red social pues en número de tweets las bodegas destacadas no poseían un alto número de notificaciones, a excepción de *Muga*, que ha demostrado tener un alto número de seguidores además de mantener una constante actividad dentro de la red de microblogging.

Por otro lado, las bodegas que sí han propiciado una acción por parte de sus seguidores para que marquen un “*Me Gusta*” son las que aglutinan más seguidores pero no son las que emiten más tweets. Esa característica se debe a la fidelidad que mantienen

estos seguidores que no permanecen en estado pasivo ante las notificaciones de las bodegas.

Todas estas interpretaciones nos dan a entender que el mercado vinícola español, y concretamente las bodegas con DOCa Rioja, siguen presentando determinadas carencias en sus comunicaciones en el mundo digital. La labor de las bodegas es hacer un buen vino y asignarle un precio atractivo pero también comunicarlo eficazmente a sus grupos de interés tanto presentes como futuros, a sus consumidores y al público en general, tanto a través de los medios de comunicación tradicionales como en los canales y plataformas de redes sociales. Las bodegas deben plantearse cuánto afecta una buena comunicación a la movilización del consumidor de vinos, cómo la comunicación crea y realza la imagen de las marcas de las bodegas, y cómo ese proceso induce a la compra. No hay que olvidar que el vino, pese a la bajada de ventas, tiene la ventaja de que es el producto alimenticio que más protagonismo tiene en los medios y es objeto de un caudal abundante de comentarios e informaciones que despiertan un notable interés entre usuarios y consumidores.

#### Agradecimientos

Este trabajo está soportado por el Ministerio de Economía y Competitividad de España bajo el proyecto NEWSOCO (ref. TIN2015-67661-P), incluyendo fondos FEDER.

#### BIBLIOGRAFÍA

- [1] K. Nelson-Field, E. Riebe y B. Sharp, «What's Not to "Like"?: Can a Facebook Fan Base Give a Brand The Advertising Reach It Needs?», *Journal of Advertising Research*, vol. 2, nº 52, pp. 262-269, 2012.
- [2] K. Smith, «Brandwatch», 2017. [En línea]. Available: <https://www.brandwatch.com>. [Último acceso: 4 Enero 2018].
- [3] S. Percastre-Mendizábal, C. Pont-Sorribes y L. Codina, «Propuesta de diseño muestral para el análisis de Twitter en comunicación política», *El profesional de la información*, vol. 26, nº 4, pp. 579-588, 2017.
- [4] Twitter, «Twitter», 2017. [En línea]. Available: <http://www.twitter.com>. [Último acceso: 2 Enero 2018].
- [5] N. Barber, T. Dodd y R. Ghiselli, «Capturing the younger wine consumer», *Journal of wine research*, vol. 19, nº 2, pp. 123-141, 2008.
- [6] M. Buelarca y S. Buelarca, «Twitter: a viable marketing tool for SMEs?», *Global Business & Management Research*, vol. 2, nº 4, pp. 296-309, 2010.
- [7] S. Wasserman y K. Faust, *Social Network Analysis: Methods And Applications (Structural Analysis in the Social Sciences)*, Cambridge: Cambridge University Press, 1994.
- [8] J. Bruwer y K. Alant, «The hedonic nature of wine tourism consumption: an experiential view», *International Journal of Wine Business Research*, vol. 21, nº 3, pp. 235-257, 2009.
- [9] Vinography, «Social Media and the Wine Industry: A New Era», 2014 Septiembre. [En línea]. Available: [http://www.vinography.com/archives/2012/02/social\\_media\\_and\\_the\\_wine\\_indu.html](http://www.vinography.com/archives/2012/02/social_media_and_the_wine_indu.html). [Último acceso: Enero 2018].
- [10] D. Wilson y S. Quinton, «Let's talk about wine: does Twitter have value?», *International Journal of Wine Business Research*, vol. 24, nº 4, pp. 271-286, 2012.
- [11] M. Stelzner, «Social Media Marketing Industry Report», *Social media examiner*, pp. 1-52, 2014.
- [12] M. Thelwall, K. Buckley y G. Paltoglou, «Sentiment in Twitter events», *Journal of the Association for Information Science and Technology*, vol. 62, nº 2, pp. 406-418, 2011.
- [13] H. Rodríguez, B. Restrepo y L. Fernando, «Conocimientos y uso del twitter por parte de estudiantes de educación superior», *Sophia*, vol. 11, nº 1, pp. 44-52, 2015.
- [14] Observatorio Español del Mercado del Vino, «OEMV», 2017. [En línea]. Available: <http://www.oemv.es/esp/oemv.php>. [Último acceso: 15 Enero 2018].
- [15] Nielsen, «Caracterización del consumidor español de vino» 2017.
- [16] C. Cochran, «Wineries embracing social networking», *San Francisco Chronicle*, p. 7, 2010.
- [17] R. Dolan, J. Conduit, J. Fahy y S. Goodman, «Facebook for wine brands: an analysis of strategies for Facebook posts and user engagement actions», de *9th Academy of Wine Business*, Adelaide, 2016.
- [18] R. Fuentes Fernández, R. Vriesekoop y B. Urbano, «Social media as a means to access millennial wine consumers», *International Journal of Wine Business Research*, vol. 29, nº 3, pp. 269-284, 2017.
- [19] R. Castro Galiana, 27 Mayo 2014. [En línea]. Available: <http://castrogaliana.com/las-bodegas-los-vinos-y-las-politicas-de-comunicacion/>. [Último acceso: 2 Febrero 2018].
- [20] J. Bruwer y G. Wood, «The Australian online wine buying consumer: motivation and behaviour perspectives», *Journal of Wine Research*, vol. 6, nº 3, pp. 193-211, 2005.
- [21] J. Scott, *Social Network Analysis: A Handbook*, Sage Publications, 2000.
- [22] D. Dearholt y R. Schvaneveldt, «Properties of pathfinder networks», de *Pathfinder associative networks: Studies in knowledge organization*, 1990, p. 1-30.
- [23] D. Pancho, J. Alonso, O. Cordon, A. Quirin y L. Magdalena, «FINGRAMS: visual representations of fuzzy rule-based inference for expert analysis of comprehensibility», *IEEE Transactions on Fuzzy Systems*, vol. 21, nº 6, pp. 1133-1149, 2013.
- [24] K. Trawinski, M. Chica, D. Pancho, S. Damas y O. Cordon, « moGrams: A Network-based Methodology for Visualizing the Set of Non-dominated Solutions in Multiobjective Optimization», *IEEE Transactions on Cybernetics*, vol. 48, nº 2, pp. 474-485, 2018.
- [25] B. Vargas-Quesada y F. Moya-Anegón, *Visualizing the structure of science*, Springer Science & Business Media, 2007.
- [26] F. Moya-Anegón, B. Vargas-Quesada, Z. Chinchilla-Rodríguez, E. Corera-Álvarez, F. Muñoz-Fernández y V. Herrero-Solana, «Visualizing the marrow of science», *Journal of the Association for Information Science and Technology*, vol. 58, nº 14, pp. 2167-2179, 2007.
- [27] A. Quirin, O. Cordon, J. Santamaría, B. Vargas-Quesada y F. Moya-Anegón, «A New Variant of the Pathfinder Algorithm to Generate Large Visual Science Maps in Cubic Time», *Information Processing and Management*, vol. 44, nº 4, p. 1611-1623, 2008.
- [28] T. Kamada y S. Kawai, «An algorithm for drawing general undirected graphs», *Information processing letters*, vol. 31, nº 1, pp. 7-15, 1989.
- [29] A. Unwin, M. Theus y H. Hofmann, *Graphics of large datasets: visualizing a million*, Springer Science & Business Media., 2008.
- [30] C. Chen y S. Morris, «Visualizing evolving networks: Minimum spanning trees versus pathfinder networks», de *Information Visualization*, 2003.
- [31] M. Zizi y M. Beaudouin-Lafon, «Accessing hyperdocuments through interactive dynamic maps», de *Proceedings of the 1994 ACM European conference on Hypermedia technology*, 1994.
- [32] S. Noel, C. Chu y V. Raghavan, «Visualization of document co-citation counts», de *IEEE Symposium on Information Visualisation*, 2002.
- [33] T. Fruchterman y E. Reingold, «Graph drawing by force-directed placement», *Software: Practice and experience*, vol. 21, nº 11, pp. 1129-1164, 1991.
- [34] S. Kobourov, «Force-directed drawing algorithms», de *Handbook of Graph Drawing and Visualization*, R. Tamassia, Ed., 2012.



# Identifying conflicts of interest of reviewers using authors bibliometric networks

V. Duarte-Martínez

Fac. de Ing. en Electricidad y Computación  
Escuela Superior Politécnica del Litoral  
Guayaquil, Ecuador  
vealduar@espol.edu.ec

A.G. López Herrera

Dept. Computer Science and  
Artificial Intelligence  
University of Granada, Granada, Spain  
lopez-herrera@decsai.ugr.es

M.J. Cobo

Dept. Computer Science and Engineering  
University of Cádiz, Cádiz, Spain  
manueljesus.cobo@uca.es

**Abstract**—The process of peer review is a very important task that must be followed by a scientific document to be approved and then published in a scientific journal. Being such a delicate process, it is required that the elected reviewers guarantee the validity and quality of the submitted work, without influencing in its decision any type of link that may exist between the authors of a scientific document and the reviewers. However, many times this goes unnoticed and the reviewers are selected only according to their experience in a given field.

This contribution proposes an approach to do recommendations based on the design of bibliometric networks such as: co-authorship networks, author co-citation networks and direct link-citation networks. In this way, we seek to discover relationships between reviewers and authors of scientific documents in order to suggest appropriate reviewers, thus avoiding the recurring problem of conflicts of interest.

**Index Terms**—Reviewers selection, bibliographic networks, co-author, author co-citation, direct link-citation

## I. INTRODUCTION

Much of the scientific job is based on the search for answers. To accomplish this, it must be performed many researches and experiments and their results are analyzed, discussed and disseminated, generally made through publications. However, in order that scientific documents become published must go through an assessment process, which includes peer review, to ensure the quality of the document and above all the validity of what has been investigated and is exposed in the document.

Scholarly peer review can be viewed as the central part of the publishing workflow, being considered necessary to ensure the quality of research journals. In fact, it must determine whether a manuscript should be accepted or rejected. This method leaves the work open to scrutiny, and often to the annotation or modification, by authors of similar or superior to the author's range. Since peer review is based in the criteria of experts, it needs of a set of experts in a particular research field (i.e. the research field of the manuscript to be reviewed) who are qualified and able to carry out an impartial review.

During this process, the role of referees is advisory. Moreover, in the scientific literature, the referees do not act as a group; not communicate with each other. Generally, they are not aware of the identity or the reports of their colleagues. In general, it is not necessary to achieve consensus. Therefore, the group dynamics are very different to a jury. Sometimes

their opinion is not unanimous. In such cases can be applied different options to make a decision.

Usually, it is desired to choose reviewers who are not close to the authors and also have no links with them. These are expected to inform publishers about potential conflicts of interest for evaluation. Some publishers or publications ask authors a list of potential arbitrators, as well as people they deem inappropriate to arbitrate their work. This is necessary, especially, when the subject of a work is so specialized that publishers cannot locate specialists in the field by themselves.

Therefore, the selection of impartial reviewers is a difficult and daunting task, since reviewers could have some conflicts of interest with the authors of the manuscript. For example, a reviewer could be a recent co-author, could be cited by the manuscript or could be usually cited by the author, which would mean, in a way that the reviewer might be interested in the publication of this manuscript. This and other issues could bias the reviewer criteria.

Usually, the selection of reviewers is based on the field of expertise of the reviewers, and the inherent and hidden social network of them is not taken into account in the process. So, in this contribution a novel approach based on bibliometric networks [1], to uncover hidden relationships between reviewers and authors, is presented. In particular, we focus on bibliometric networks based on the social aspects, i.e., authors. To do that, co-author, author co-citation and author direct link citation networks are used to build a global social bibliometric network.

## II. BIBLIOGRAPHIC NETWORKS

Networks provide an interesting abstraction of a variety of complex systems [2], such as, social networks or biological networks. Moreover, scientific knowledge could be understood as a complex system, where the network structure is frequently used to model the interaction of scientific actors (authors, journals, keywords, references, etc.).

On the other hand, bibliometric is dedicated to the analysis of the scientific output. Formally, Bibliometrics are a set of methods, which can be used to analyze academic literature quantitatively and its changes over time [3]. It is an important tool for assessing and analyzing the academic research output contributing to the progress of science in many different ways.

There are two main bibliometric methods for exploring a research field: performance analysis and science mapping [4]. While performance analysis aims to evaluate the citation impact of the scientific production of different scientific actors [5], science mapping aims at displaying the conceptual, social or intellectual structure of scientific research and its evolution and dynamical aspects [6] [7].

As above mentioned, the scientific knowledge can be represented as a graph. In this sense, science mapping analysis uses bibliographic networks [1] in order to represent the different relationships among scientific actors. Depending on the kind of aspects that will be represented, three kind of networks could be identified:

- Collaboration networks are used to show how authors or institutions relate to others in the field of scientific research. The most common kind of collaboration network are co-author networks. With this type of network can be discovered, for example, groups of regular authors, influence authors, hidden communities of authors, relevant institutions in a specific research field, etc. [8]
- Conceptual networks [9] represent relations between concepts or words in a set of publications. That means that, for instance, words which appear together in a document, will be related in a network. It is also known as co-word network. This type could be used to understand the topics covered by a research field [10], to define which are the most important and the most recent issues. It could also help in the study of the evolution of subjects over time and it could give good impression of cognitive relations between different research groups.
- Publication Citation networks [11] [12] show relationships between nodes which represent publications, while the edges can have different interpretations depending on the network type (co-citation, bibliographic coupling or direct link).

In this contribution we focus on the social bibliographic network which have become a very important topic of study that has attracted the attention of researchers because these kinds of networks represent a good prototype of complex evolving system to explore, where the network is constantly expanding with the occurrence of new authors of scientific documents, or new links between existing authors.

These networks are studied with two main aims. Mainly, to evaluate the collaboration status of scientific disciplines, that is related with bibliometric mapping, assisting in discovering of structural and dynamic aspects of scientific research, to better understand the organization of scientific fields and their evolution [6]. And also, to examine the performance of social structure of collaboration networks, using techniques of social networks analysis [13].

In Bibliometrics, social bibliographic networks are analyzed using indicators to measure and extract the inherent structure to a set of publications; but also these are studied as social networks to explore interactions between actors who may be researchers, groups, institutions, etc. that collaborate in the development of scientific papers on research topics. These are

usually weighted to represent the strength of different relations between actors.

Social bibliographic networks might reveal substantial knowledge such as: researcher communities, professional interactions between scientists, central nodes that act as hubs, leaders or gatekeepers; highly connected groups; and patterns of interactions between groups [14]. Very large networks can be assembled in this way.

### III. METHODOLOGY

As above mentioned, different bibliographic networks have been proposed based on co-occurrence, coupling and direct link. Moreover, depending of the selected unit of analysis, different aspects could be uncovered. The approach presented in this contribution focuses on the social aspects.

Particularly, in a research document the unit of analysis author can be found in two different parts. The former is the authors list, being the authors who write the research document. The latter is the author-references list, which are the authors cited by the research document (the intellectual social base). Using these two types of author lists, three kinds of bibliometric networks can be built: co-author, author co-citation and author direct link citation.

- Co-author networks, are those containing all authors of a document and related to each other, i.e. two scientists are considered connected if they have coauthored one or more papers together. Such networks reflect groups of researchers in scientific fields.
- Author co-citation networks, are those which relate all authors referenced in a document to each other. This kind of networks shows author groups which are referenced together in the same papers.
- Author direct citation networks, are those that express the direct relationship between the author of a document and the cited author, that is, it shows the authors cited by other authors. This information shows a very important social factor that may allow discover which are the inspirations of a creator author, and the bases that allows the author to develop his/her research.

These networks show us the connections that may arise between two researchers, according to the nature of their link, and represent the main study object in this document, for example, let suppose a set of three research documents where each document is composed of a set of authors, and a set of authors in the references list as it is shown in Table I. Thus, the three social bibliometric networks built from this example corpus are shown in Figure 1.

TABLE I  
EXAMPLE CORPUS.

Document	Authors	Authors in reference
Document 1	a1, a2, a3	a2, a4
Document 2	a2, a3, a4	a1, a3, a5
Document 3	a1, a3, a5	a2, a4, a6

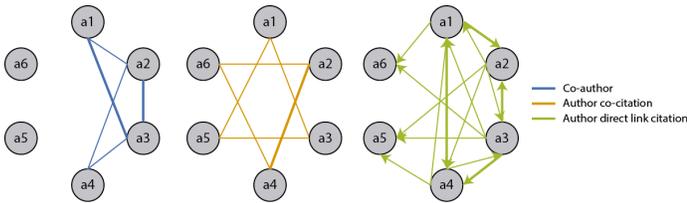


Fig. 1. Example of bibliometric network.

We should point out that an arc between two nodes represents a bibliometric relation between these authors. Also, the thickness of the arcs represents the raw co-occurrence or number of direct links depending on the kind of relationships.

Once the three kinds of bibliometric networks have been built, three levels of social relationships could be assessed:

- Level 1: authors who have only one kind of social relationship. At this level we just focus in one kind of relationship, and the remaining ones are not taken into account.
- Level 2: authors who have two kinds of social relationships. In this level, two authors could 1) collaborate together in a document and be co-cited, or 2) collaborate together in a document and have a direct link citation relationship between them, or 3) be co-cited and have a direct link citation between them.
- Level 3: authors who have the three kinds of social relationships. In this case, two authors collaborate together in (at least) a paper, are co-cited and also one of them cites to the other.

The above mentioned levels of relationships can be used to achieve the grade of conflict of interests between researchers. Therefore, from a set of bibliographic records downloaded from a bibliographic database (e.g. WoS or Scopus), a whole network containing the three types of relationship can be built.

Thus, from a set of documents related with a research field, a set of reviewers candidates could be achieved based on their bibliographic social relationships in order to avoid possible biases. To do that, the journal office should look at the social bibliometric relationships between the authors of the submitted manuscript and the reviewer community / panel in order to avoid biased reviewers. Furthermore, based on the three kinds of levels of social relationships, we propose an algorithm to identify different levels of bias prevention that could be configured. It is described as follows:

Having a graph  $G$  with a set of nodes  $V$  and edges between nodes  $V_i, V_j \in G$ . It is assumed that  $V_i$  is a document author while  $V_j$  is a reviewer candidate. Therefore, we could assess levels using the following inclusion criterion: **For each edge**  $(V_i, V_j)$  where  $V_i \neq V_j$ , level of bias prevention will be **Level 1** if  $V_i$  co-cited  $V_j$  or  $V_i$  co-authored  $V_j$  or  $V_i$  direct link cited  $V_j$ . Otherwise, level of bias prevention will be **Level 2** if  $(V_i$  !co-cited  $V_j$  and  $V_i$  !co-authored  $V_j)$  or  $(V_i$  !co-authored  $V_j$  and  $V_i$  !direct link cited  $V_j)$  or  $(V_i$  !co-cited  $V_j$  and  $V_i$  !direct link cited  $V_j)$ . In any another way, level of bias prevention will

be **Level 3** if  $V_i$  !co-cited  $V_j$  and  $V_i$  !co-authored  $V_j$  and  $V_i$  !direct link cited  $V_j$ .

The Level 3 is the most restrictive one. That means that the authors of the submitted manuscript and the reviewer candidate never appear together (neither in the author list, neither in the author-reference list) in any paper, in spite of, they investigate in the same research area. The Level 3 suggests no bias or conflicts of interest among authors and reviewers candidates, those last are supposed impartial. In Figure 2, it is shown a Venn diagram to explain the intersection of these three levels where each type of relationship is represented as a set and the levels are: The level 1, the less least restrictive, that covers every relationship; the Level 2, which allows the existence of two types of relationships at the same time; and the Level 3, which does not allow any kind of relationship.



Fig. 2. Different levels of bias prevention.

Thus, the level of rigor to be established depends on the editor's criteria; however, here is proposed this methodology that aims to deal with the problem of conflict of interest in scientific collaboration.

#### IV. CASE STUDY

With the aim of showing the applicability of this approach, a case of study have been built. It is described with details as follows.

Initially, we have collected data from Scopus database. For this, we have chosen 3891 research papers about Cloud Computing thematic only because this is a hot topic in Computer Sciences field.

Then, we have had used preprocessing techniques to decompose bibliographic data in order to extract specific data about principal authors and referenced authors. Afterwards, we have been able to build different bibliometric networks mentioned previously, that is, co-author, author co-citation and direct link citation networks. In these networks, we can explore

through their relationships and we can realize, as is logical, that an author related to another directly would not be a good candidate to be selected as a reviewer of a scientific document of him, but through these relationships you can navigate to find other researchers who have worked in the same subject but not related to the main author. The more levels of relationship are excluded, the more reliable it can be assured that there will be no conflicts of interest, obviously this can be assured from the point of view that encompasses scientific work.

In this analysis, the objective has been to find relationships of the type: *Friend of my friend who is not my friend*, taken to the field of research, Understanding that, if two researchers A and B have worked together, as collaborators of a scientific document, then from A and from B you can find possible reviewers candidates that are not related to A and/or B but with other researchers who have worked with authors A and B. In this way it is sought to avoid choosing reviewers of scientific articles that could have conflicts of interest with the authors of an article sent to a specific journal. The journal office, after receive the original manuscript, could use this analysis in order to select and recommend the best reviewers within the research area of the article, along with avoiding of conflict of interest, that is, authors which have no direct relationship with the authors of the submitted document (not cited author, or not collaborator).

To demonstrate this approach, we study each type of network that is generated from an author. For example, we have chosen, at random, an author of scientific documents dealing with the subject of this case study (Cloud Computing), the researcher Zheng Q. (Zheng, Qinghua). From this, co-author network, co-citation network and direct link citation network have been generated.

In Figure 3, we can see the co-author network built from one author (Zheng Q.) where the principal researcher is in purple node. In addition, the authors with whom he has shared co-authorship in scientific documents (Li J., Zhang J., Li X. and Li R.) are represented with orange nodes. From each author that have worked with Zheng Q. we have gotten all the recommended authors which are represented with green nodes. Recommended researchers are those who have worked with others who have co-authored scientific documents with Zheng Q., but have not worked directly with him. This would be the minimum level of connection that should be considered, although we could explore more in networks until we can find even more indirect relationships. In Table II, the list of recommended authors can be seen. We have pruned the networks built to show only 15 recommended authors thinking of simplifying the visualization of the results in this example.

We have also generated the co-citation network for the author, this means that the network has been built with all the relationships defined by the authors referenced in the scientific documents written by Zheng Q. This network can be seen in Figure 4, where node in purple color represents the principal author, orange nodes represents authors referenced in papers written by Zheng Q. and green nodes represents recommended authors. Summarized data can be seen in Table III.

TABLE II  
TABLE OF RECOMMENDATIONS FROM CO-AUTHOR NETWORKS.

Recommended Author
Cao Y.
Chen L.-X.
He T.-Q.
Lee S.-Y.
Li B.
Li C.
Liao S.
Su D.
Su G.
Wong D.W.S.
Xu P.
Xue W.
Yang Y.
Yu N.
Zhou F.-F.

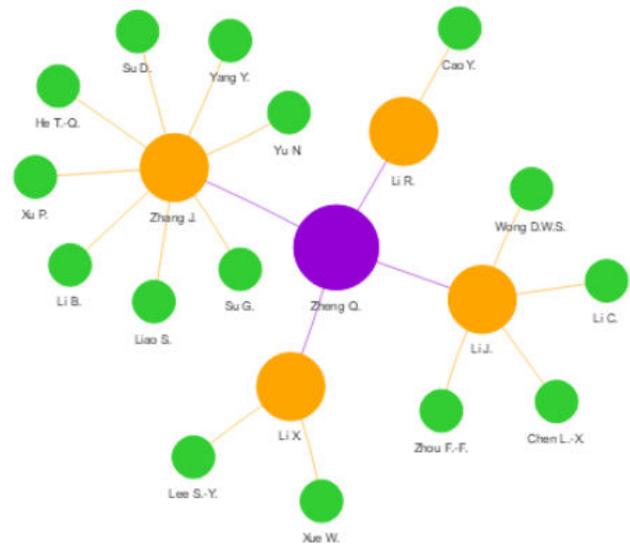


Fig. 3. Recommendations from co-author graph.

And finally, we have built an author direct link citation network. It models the relationships between the author and all cited authors in reference section from a scientific document. The Figure 5, shows the built graph where principal author, Zheng Q. is shown in purple node, referenced authors are shown in orange nodes and recommended authors are shown in green color. The list of recommended author is shown in the Table IV.

With all these recommended authors, we can identify who are those that fit in each level of bias prevention, according to what is established in section III. However, since the complete networks are very extensive (especially the co-citation networks that could contain thousands of relationships) we have summarized the results obtained. In Table V, it is shown some scientific authors that belong to level 1, level 2 and level 3 respectively. This means that, for example. the author Cheng



TABLE V  
TABLE OF BIAS PREVENTION LEVELS.

Level 1	Level 2	Level 3
Chao K.-M.	Campbell R.H.	Chen C.
Chen L.-X.	Cao Y.	Lee S.-Y.
Dunagan J.	Cardellini V.	Su G.
Ghaffarkhah A.	Hara T.	Xue W.
He T.-Q.	Jararweh Y.	Yan Z.
Letier E.	Li C.	
Ma X.	Liao S.	
Megiddo N.	Pernici B.	
Mignot J.-C.	Rong H.	
Nagin K.	Su D.	
Ota K.	Wong D.W.S.	
Paraiso F.	Yu N.	
Rai A.	Zhou F.-F.	
Safieddine I.		
Sharma A.K.		
Sivic J.		
Talbi E.-G.		
Tam A.S.W.		
Tan K.		
ValiKardan S.		
Wakelam V.		
Williams P. Xu P.		
Yang K.		
Yang Y.		
Zhu M.		

Reviewers must act following an ethic rules and conflict of interests must be avoided. The criteria of the researchers could be biased by several aspects: i) collaboration (e.g. co-authorship), ii) social relationship (e.g. belonging to the same department), and iii) intellectual (e.g. reviewer could be cited several time). In fact, the biases could be positive or negative. That is, a reviewer could favor or work against the author. Some of these effects could be avoided using a blind review, where the reviewers do not know the identity of the authors.

In this sense, the selection of reviewer without conflict of interests with the author could be a difficult task, since a reviewer should not have interacted socially with the author.

As above mentioned, researchers have many kinds of relationships with their colleagues in their academic life. These interactions could be modeled as a bibliographic network, where the nodes are the researchers and the edges are the interactions among them.

In this contribution, a novel approach to identify potential reviewers without conflict of interest based on social bibliographic networks is presented. Particularly, three kinds of social network are used: co-author, author co-citation and author direct link citation.

Using this variety of scientific social networks, three levels of social relationships can be determined. Therefore, three levels of bias prevention could be used, being the level 3, the most restrictive, where a researcher could be a reviewer if he/she never appear as co-author, neither in the author reference list.

For this, the transitivity property of networks have been studied in order to find possible candidates for reviewers using an undirected relationship between authors that we have called: *Friend of my friend who is not my friend*. This is an application of the transitivity property that indicates the fact that a node  $A$  knows a node  $B$  and a node  $B$  knows a node  $C$  does not guarantee that  $A$  knows  $C$ . Therefore, with these candidates we can apply level 3 of bias prevention in order to find real good possible reviewers.

The presented approach could be used by journal officers or panel experts in order to select the most suitable reviewers to evaluate different kind of research outputs.

As future work, we propose to include in the preprocessing process a disambiguation task in order to avoid the problem of finding two or more nodes that actually represent the same person. For instance, we have found {DÍAZ BRUGERA, JAVIER} and {DÍAZ BRUGUERA, JAVIER} which obviously refers to the same person but his/her name is misspelled.

#### ACKNOWLEDGMENT

This study was funded by FEDER funds in the Spanish Department for Economy and Competitiveness project (TIN2016-75850-R).

#### REFERENCES

- [1] V. Batagelj and M. Cerinšek, "On bibliographic networks," *Scientometrics*, vol. 96, no. 3, pp. 845–864, 2013.
- [2] S. Boccaletti, V. Latora, Y. Moreno, M. Chavez, and D. U. Hwang, "Complex networks: Structure and dynamics," pp. 175–308, 2006.
- [3] M. Cobo, A. López-Herrera, E. Herrera-Viedma, and F. Herrera, "An approach for detecting, quantifying, and visualizing the evolution of a research field: A practical application to the Fuzzy Sets Theory field," *Journal of Informetrics*, vol. 5, no. 1, pp. 146–166, 2011.
- [4] E. Noyons, H. Moed, and M. Luwel, "Combining mapping and citation analysis for evaluative bibliometric purposes: A bibliometric study," *Journal of the American Society for Information Science*, vol. 50, no. 2, pp. 115–131, 1999.
- [5] J. E. Hirsch, "An index to quantify an individual's scientific research output," *Proceedings of the National Academy of Sciences*, vol. 102, no. 46, pp. 16 569–16 572, 11 2005.
- [6] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, "Science mapping software tools: Review, analysis, and cooperative study among tools," *Journal of the American Society for Information Science and Technology*, vol. 62, no. 7, pp. 1382–1402, 2011.
- [7] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, "SciMAT: A new science mapping analysis software tool," *Journal of the American Society for Information Science and Technology*, vol. 63, no. 8, pp. 1609–1630, 2012.
- [8] W. Glanzel, "National characteristics in international scientific co-authorship relations," *Scientometrics*, vol. 51, no. 1, pp. 69–115, 2001.
- [9] M. Callon, J.-P. Courtial, W. A. Turner, and S. Bauin, "From translations to problematic networks: An introduction to co-word analysis," *Social Science Information*, vol. 22, no. 2, pp. 191–235, 3 1983.
- [10] M. Cobo, M. Martínez, M. Gutiérrez-Salcedo, H. Fujita, and E. Herrera-Viedma, "25years at Knowledge-Based Systems: A bibliometric analysis," *Knowledge-Based Systems*, vol. 80, pp. 3–13, 5 2015.
- [11] M. M. Kessler, "Bibliographic coupling between scientific papers," *American Documentation*, vol. 14, no. 1, pp. 10–25, 1963.
- [12] H. Small, "Co-citation in the scientific literature: A new measure of the relationship between two documents," *Journal of the American Society for Information Science*, vol. 24, no. 4, pp. 265–269, 7 1973.
- [13] C. C. Aggarwal, Ed., *Social Network Data Analytics*. Boston, MA: Springer US, 2011.
- [14] S. Wasserman and K. Faust, *Social network analysis : methods and applications*. Cambridge University Press, 1994.

# Science Mapping Artificial Intelligence

Benjamín Vargas-Quesada  
Departamento de Información y  
Comunicación  
Universidad de Granada.  
Granada, Spain  
e-mail: [benjamin@ugr.es](mailto:benjamin@ugr.es)

Zaida Chinchilla Rodríguez  
Instituto de Políticas y Bienes  
Públicos (IPP). Consejo Superior de  
Investigaciones Científicas (CSIC).  
Madrid, Spain  
e-mail: [zaida.chinchilla@cchs.csic.es](mailto:zaida.chinchilla@cchs.csic.es)

Antonio Perianes-Rodríguez  
Departamento de Biblioteconomía y  
Documentación.  
Universidad Carlos III  
Madrid, Spain  
e-mail: [antonio.perianes@uc3m.es](mailto:antonio.perianes@uc3m.es)

**Abstract**— Mediante *science mapping*, se muestra la visualización de la estructura intelectual de la inteligencia artificial, a nivel mundial. Se identifican sus principales líneas de investigación a partir de las citas de sus trabajos, como interactúan entre sí, mediante la detección de los nodos con un alto grado de centralidad de *betweenness* o intermediación, así como el nivel de actividad, de cada una de ellas, por medio del uso de un indicador denominado *citation burst*. Se finaliza con un estudio longitudinal y evolutivo de las líneas detectadas.

**Keywords**— *Science Mapping; Inteligencia Artificial; Líneas de Investigación.*

## I. INTRODUCCIÓN

Hace más de 50 años, que Moreno [1] propuso el uso de las redes sociales para analizar el comportamiento humano y detectar patrones e individuos relevantes dentro de las mismas. Hoy día, el concepto de red social ha cambiado, trasladándose la representación gráfica de las interacciones entre los individuos o entidades (grafos), a denominar a las compañías que ofrecen servicios de redes y medios sociales.

La aparición del *big data* ha permitido que grandes conjuntos de datos, que hasta hace poco, eran imposibles de procesar mediante el uso de herramientas tradicionales debido a su tamaño y complejidad, puedan ahora ser tratados y utilizados con fines analíticos y de predicción. La combinación del *big data*, *datamining*, bibliometría y redes sociales, ha dado lugar a lo que se ha denominado como *science mapping* [2], cuyo objetivo es visualizar la estructura y relaciones de la ciencia en general, y de las áreas científicas, disciplinas, líneas de investigación, autorías, etc., en particular. *Science mapping* ha sido utilizado para mostrar la columna vertebral de la ciencia a nivel mundial [3], representar y analizar la estructura de grandes bases de datos científicas [4] y, visualizar la estructura intelectual del grafeno, sus principales líneas de investigación y evolución mundial [5], entre otras importantes iniciativas. Hasta donde llega nuestro conocimiento, no hay ningún trabajo que visualice la estructura intelectual de la IA, ni que detecte e

identifique sus principales líneas de investigación, a partir de ella. Este trabajo persigue los siguientes objetivos:

- Visualizar y analizar la estructura de la red de la Inteligencia Artificial (IA).
- Identificar las principales líneas de investigación.
- Localizar los trabajos que actúan como conectores de las líneas de investigación.
- Detectar tendencias emergentes de investigación.
- Realizar un breve estudio longitudinal de las principales líneas de investigación.

## II. MATERIAL Y MÉTODOS

Por medio de la consulta:  $WC=(Computer\ Science, Artificial\ Intelligence)$  AND  $TS=(Artificial\ Intelligence)$ , filtrando por *papers, proceedings paper o reviews*, el 28 de mayo de 2018, descargamos de Web of Science 8.635 documentos publicados entre 1971 y 2017, conteniendo un total de 172.109 referencias. Para la visualización y análisis de los datos, hemos utilizado *CiteSpace*, que es un *software* gratuito diseñado específicamente para este tipo de tareas. En aras a nuestro objetivo principal, utilizamos las relaciones de citación de los documentos descargados, para establecer la estructura intelectual e identificar los clusters o líneas de investigación. Cada línea es etiquetada en base a los *keywords* de los artículos que las citan, como se indica en la Figura 1.

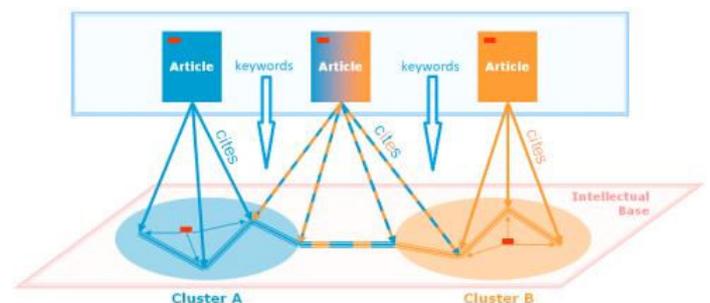


Fig. 1. Proceso para la detección y etiquetado de líneas de investigación

El uso de las citas, al igual que otras unidades de análisis de corte bibliométrico como son los autores, términos

extraídos de títulos y/o resúmenes, keywords, etc., podría ser considerado como una limitación, por las distorsiones que algunas de sus características inherentes como la intencionalidad, cobertura, popularidad, etc., pueden causar. Para salvar esta limitación, en cada visualización, se han establecido periodos de 5 años, y sólo se han representado los 50 documentos más citados de cada periodo. De esta forma se reduce en gran medida las distorsiones que se puedan producir, al representar la opinión consensuada de los autores, mediante sus citas.

### III. RESULTADOS

Las visualizaciones y resultados aquí mostrados, pueden ser replicados mediante el programa *Citespace*, disponible en: <http://cluster.cis.drexel.edu/~cchen/citespace>, en combinación con los registros descargados de Web of Science, accesibles

en:

<https://www.dropbox.com/sh/5i0nb0npcsavg4/AAA4uGb05fsCLN-L-18jekZca?dl=0>.

#### A. Estructura de la Red de IA

La red de IA a nivel mundial, cuenta con 382 nodos, 805 enlaces y una densidad de 0.011. El componente de mayor tamaño, Figura 2, está compuesto por un total de 287 nodos (75% de la red total). Mediante el método de Ward [6], se han identificado 8 clusters o líneas principales de investigación. La modularidad Q [7] de la red, es de 0.8066, indicando que está dividida en líneas de investigación altamente enlazadas y relacionadas entre sí. Su media Silhouette [8] es de 0.3387, sugiriendo, que la homogeneidad de dichas líneas es más bien baja.

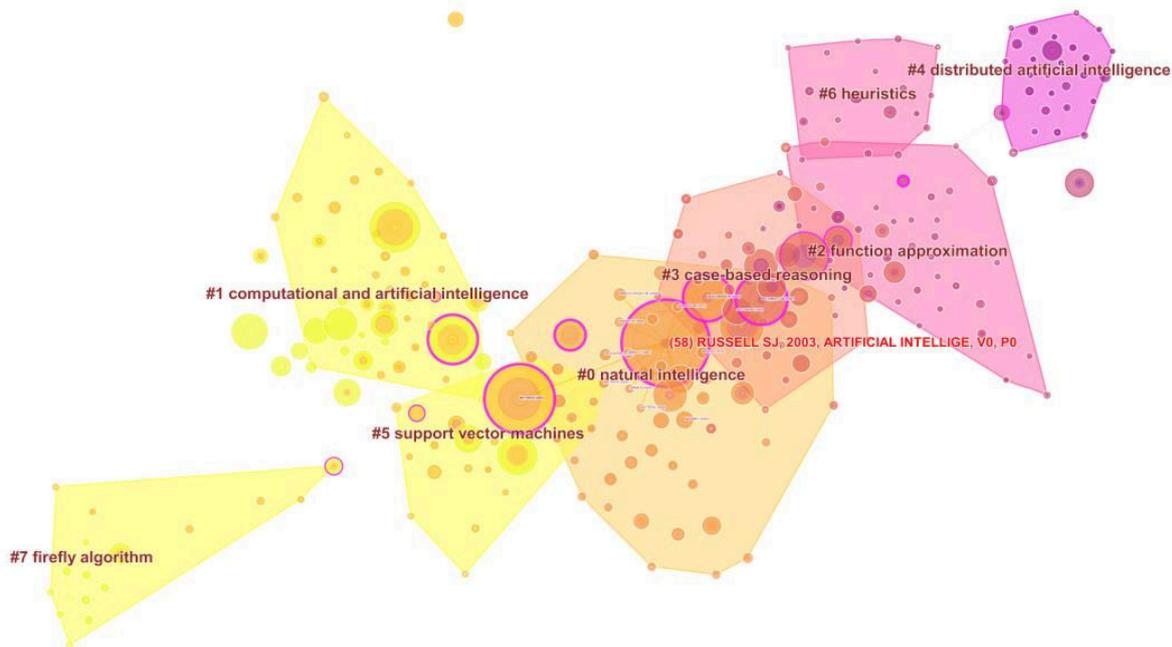


Fig. 2. Science map mundial de IA y principales líneas de investigación

#### B. Principales Líneas de Investigación

Para su denominación, hemos recurrido a los *keywords* de los artículos fuente de cada línea, seleccionando el más representativo mediante el algoritmo likelihood ratio, por sus buenos resultados en cobertura y unicidad. Por orden de tamaño, las principales líneas de investigación son las siguientes: *Natural intelligence*, *Computational and artificial intelligence*, *Function aproximation*, *Case-based reasoning*, *Distributed artificial intelligence*, *Support vector machines*, *Heuristics*, y *Firefly algorithms*, como se puede ver en la Figura 2, precedidas por el símbolo #.

#### C. Trabajos Responsables de Conectar las Líneas de Investigación

La centralidad de intermediación (*betweenness*) de un nodo en una red, mide el grado en que el nodo es parte de *paths* que conectan otros nodos [9]. En este caso, con valores comprendidos entre 0 y 1, la utilizamos para detectar las referencias responsables de conectar distintas líneas de investigación. Las referencias con un *betweenness* alto, se muestran con un borde morado. Cuanto más grueso es el borde, mayor es su valor de intermediación, ver Figura 2. Por ejemplo, el trabajo de Russell SJ, 2003, *Artificial Intelligence*, tiene una centralidad de 0.37, la más alta de toda la red, y es el responsable de la conexión de las líneas de investigación *Natural intelligence*, *Computational and artificial intelligence*, *Case-base reasoning* y *Support vector machines*. Este análisis es extensible al resto de nodos de color rojo, en función de su tamaño.

D. Detectar tendencias emergentes de investigación

Citation burst (explosión de citas) [10], es un indicador utilizado para la detección de referencias y líneas de investigación activas, que reciben un elevado número de citas durante uno o varios años. La explosión de citas, proporciona la evidencia de que un trabajo concreto ha atraído un alto grado de atención por parte de sus colegas, reflejándolo

mediante sus citas, Figura 3. Si una línea de investigación contiene numerosas referencias de este tipo, se puede considerar que es muy activa y con una tendencia emergente. Si un nodo presenta un círculo rojo en su interior, Figura 4, indicará que atrae un gran número de citas. A mayor *citation burst*, mayor tamaño del círculo.

Top 25 References with the Strongest Citation Bursts

References	Year	Strength	Begin	End
KOLODNER J, 1993, CASE BASED REASONING, V0, P0	1993	11.5028	1996	2001
PEARL J, 1988, PROBABILISTIC REASON, V0, P0	1988	11.2276	1991	1996
GOLDBERG DE, 1989, GENETIC ALGORITHMS S, V0, P0	1989	10.5589	1991	1997
BROOKS RA, 1991, ARTIF INTELL, V47, P139, DOI	1991	8.8768	1995	1998
WOOLDRIDGE M, 1995, KNOWL ENG REV, V10, P115, DOI	1995	8.3438	1997	2003
BOND AH, 1988, READINGS DISTRIBUTED, V0, P0	1988	7.6561	1991	1995
WINOGRAD T, 1986, UNDERSTANDING COMPUT, V0, P0	1986	5.7848	1991	1994
WATERMAN D, 1986, GUIDE EXPERT SYSTEMS, V0, P0	1986	5.7848	1991	1994
RUMELHART DE, 1986, PARALLEL DISTRIBUTED, V1, P0	1986	5.2037	1991	1994
MINTON S, 1992, ARTIF INTELL, V58, P161, DOI	1992	4.9822	1997	2000
HAYESROTH B, 1985, ARTIF INTELL, V26, P251, DOI	1985	4.7946	1991	1993
HARNAD S, 1990, PHYSICA D, V42, P335, DOI	1990	4.6658	1993	1998
REITER R, 1987, ARTIF INTELL, V32, P57, DOI	1987	4.5838	1992	1995
NORVIG P, 1995, ARTIFICIAL INTELLIGE, V0, P0	1995	4.4763	1996	2003
GENESERETH MR, 1987, LOGICAL F ARTIFICIAL, V0, P0	1987	4.3618	1991	1995
RICH E, 1991, ARTIFICIAL INTELLIGE, V0, P0	1991	4.3304	1993	1999
KUIPERS B, 1986, ARTIF INTELL, V29, P289, DOI	1986	4.2375	1992	1994
RIESBECK CK, 1989, INSIDE CASE BASED RE, V0, P0	1989	4.2184	1992	1997
NEWELL A, 1990, UNIFIED THEORIES COG, V0, P0	1990	4.2055	1993	1995
GASSER L, 1991, ARTIF INTELL, V47, P107, DOI	1991	4.0773	1992	1999
DECHTER R, 1991, ARTIF INTELL, V49, P61, DOI	1991	4.0773	1992	1999
DEKLEER J, 1986, ARTIF INTELL, V28, P127, DOI	1986	4.0433	1991	1994
WELLMAN MP, 1993, J ARTIF INTELL RES, V1, P1	1993	4.0285	1996	1999
GASSER L, 1989, DISTRIBUTED ARTIFICI, V2, P0	1989	3.8146	1991	1995
SUCHMAN LA, 1987, PLANS SITUATED ACTIO, V0, P0	1987	3.8146	1991	1995

Fig. 3. Top 25 trabajos con mayor citation burst

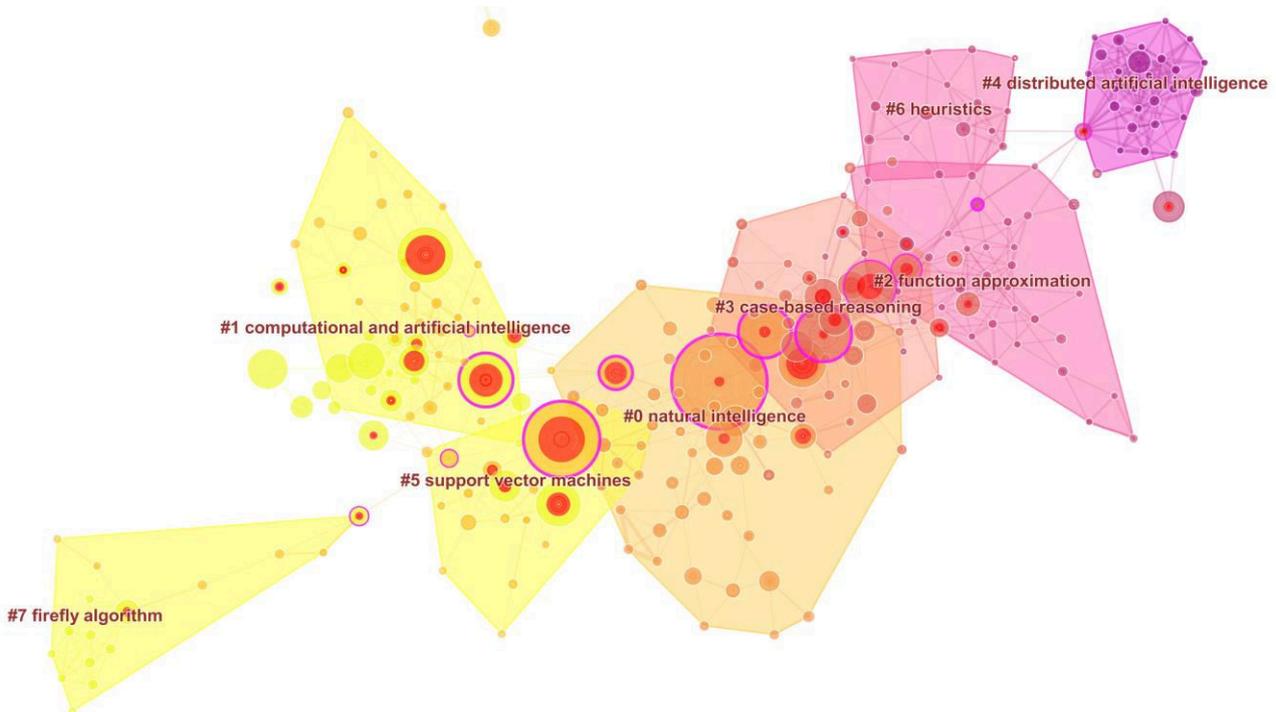


Fig. 4. Representación de los Top 25 trabajos con mayor citation burst

Por ejemplo, la línea de investigación 3 *Case-based reasoning*, contiene bastantes trabajos con un nivel de *citation burst* elevado, mostrando su alto nivel de actividad y emergencia. Así, el trabajo de Kolodner J, 1993, Case Based Reasoning, con un valor de 11,5028, seguido muy de cerca del de Pearl J, 1988, Probabilistic Reason, con 11,2276 de *citation burst*, respectivamente, ponen de manifiesto el amplio uso de estos trabajos y la relevancia de esa la línea de investigación.

E. Breve estudio longitudinal de las principales líneas de investigación etectar tendencias emergentes de investigación

*Timeline view*, Figura 5, es un tipo de representación que proporciona una visualización de la red por medio de líneas de tiempo horizontales. En este caso, se ha dividido en periodos

de cuatro años y la etiqueta de cada línea de investigación, aparece al final de la línea temporal, a la derecha. Las referencias citadas, se representan con círculos con un tamaño proporcional a la cantidad de citas recibidas en ese segmento de tiempo. Por lo tanto, un gran tamaño denota una referencia altamente citada. El color de cada referencia se corresponde con el segmento de tiempo en el que fueron citadas, pero se posicionan en base al año en que fueron publicadas. Además, se utilizan otro tipo de colores, explicados anteriormente, para resaltar atributos especiales como el *betweenness* o el *citation burst*. En este caso, las líneas que conectan dos referencias en la visualización, representan enlaces de cocitación, e indican la relación entre ellas, así como entre las líneas de investigación a las que pertenecen.

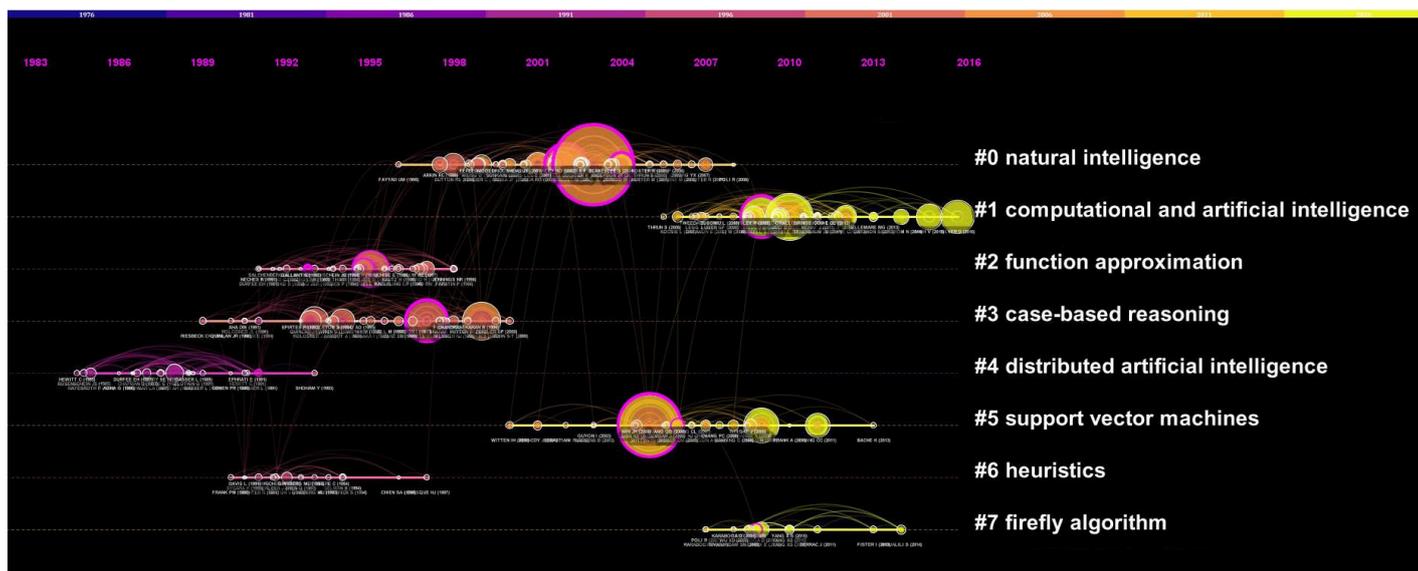


Fig. 5. *Timeline view* de las principales líneas de investigación

A nivel general y de forma breve, podemos decir que las líneas de investigación que se nutren de conocimientos más lejanos en el tiempo son *Distributed artificial intelligence* y *Heuristic*, pero sobre todo, la primera. Son líneas muy consolidadas, pero que no reciben muchas citas, como indica el tamaño de sus nodos, también son bastante lejanas en el tiempo, como muestra el color de sus nodos. Esto revela poca actividad, y una base de conocimiento con poca evolución.

*Function approximation* y *Case-base reasoning*, también son líneas consolidadas que se alimentan mucho de trabajos pretéritos. No obstante, sus citas son de fechas más recientes, y son puntos importantes de interconexión con otras líneas, como muestran las aureolas moradas de muchos de sus nodos. Son también bastante activas y atraen la atención de los investigadores, como podemos ver por su elevado número de nodos rojos.

*Natural intelligence* es la línea de investigación de mayor tamaño, la que más interrelaciona con el resto, como indica el contar con la referencia de mayor *betweenness*, así como otras con valores similares, a la vez que permanece bastante activa. Su número de citas no es muy elevado, pero sí es superior a las anteriores líneas de investigación.

*Computational and artificial intelligence*, *Support vector machines* y *Firefly Algorithm*, son las líneas con un mayor número de citas recientes. Sobre todo la primera.

*Computational and artificial intelligence* y *Support vector machines*, reciben un número elevado de citas a lo largo del tiempo, tienen trabajos con un elevado índice de *citation burst*, y cuentan con referencias con un alto grado de *betweenness*, permitiéndoles relacionarse entre sí y sobre todo, con *Natural intelligence*.



*Firefly Algorithm* es una línea joven, como se observa en su momento de aparición y las fechas de las citas que recibe, pero ya cuenta con varias referencias que le permiten ser una línea activa e interconectada con el resto.

#### IV. CONCLUSIONES

Mostramos por primera vez la red de la estructura intelectual de la IA a nivel mundial. Se han identificado ocho líneas principales de investigación altamente relacionadas entre sí, a la vez que poco homogéneas a nivel individual. Cinco de ellas están muy consolidadas y tres, son de más reciente aparición. Prácticamente, todas las líneas interactúan entre sí, pero sobre todo lo hace *Natural intelligence*, que es a su vez la de mayor tamaño. Son especialmente activas, por el número de citas que atraen: *Case-based reasoning*, *Computational and artificial intelligence* y *Support vector machines*.

#### BIBLIOGRAFIA

- [1] J.L. Moreno. Who shall survive? Beacon House, New York, 1953.
- [2] M.J. Cobo, A.G. López-Herrera, E. Herrera-Viedma and F. Herrera. "Science mapping software tools: Review, analysis, and cooperative study among tools". *Journal of the American Society for Information Science and Technology*, vol. 62, nº 7, pp. 1382-1402, 2011.
- [3] F. Moya-Anegón, B. Vargas-Quesada, Z. Chinchilla-Rodríguez, E. Corera-Álvarez, F.J. Muñoz-Fernández, and V. Herrero-Solana, "Visualizing the marrow of science". *Journal of the American Society for Information Science and Technology*, vol. 58, pp. 2167-2179, 2007.
- [4] A.J. Gómez-Núñez, B. Vargas-Quesada, Z. Chinchilla-Rodríguez, V. Batagelj, and F. Moya-Anegón, "Visualization and analysis of SCImago Journal & Country Rank structure via journal clustering", *Aslib Journal of Information Management*, vol. 68, nº 5, pp. 607-627, 2016.
- [5] B. Vargas-Quesada, Z. Chinchilla-Rodríguez, and N. Rodríguez, "Identification and Visualization of the Intellectual Structure in Graphene Research", *Frontiers in Research Metrics and Analytics*, vol. 2, pp. 1-22, 2017.
- [6] J.H.Jr. Ward, "Hierarchical Grouping to Optimize an Objective Function", *Journal of the American Statistical Association*, vol. 58, pp. 236-244, 1963.
- [7] C. Chen, "Predictive effects of structural variation on citation counts", *Journal of the American Society for Information Science and Technology*, vol. 63, nº 3, pp. 431-449, 2012.
- [8] C. Chen, F. Ibekwe-SanJuan, and J. Hou, "The structure and dynamics of co-citation clusters: a multiple-perspective co-citation analysis". *Journal of the American Society for Information Science and Technology*, vol. 61, nº 7, pp. 1386-1409, 2010.
- [9] L.C. Freeman, "A set of measuring centrality based on betweenness", *Sociometry*, vol. 40, pp. 35-41, 1977.
- [10] J. Kleinber, "Bursty and hierarchical structure in streams", 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining Edmonton, Alberta, Canada, 2002, <http://www.cs.cornell.edu/home/kleinber/bhs.pdf>



---

# **I Workshop en Ciencia de Datos en Redes Sociales (CidReS 2018)**

SESIÓN 2







# On the analysis of the influence of the evaluation metric in community detection using GRASP

Sergio Pérez-Peló

Dept. of Computer Sciences

Universidad Rey Juan Carlos

C/Tulipán, S/N, 28933, Móstoles, Spain

Email: sergio.perez.pelo@urjc.es

Jesús Sánchez-Oro

Dept. of Computer Sciences

Universidad Rey Juan Carlos

C/Tulipán, S/N, 28933, Móstoles, Spain

Email: jesus.sanchezoro@urjc.es

Abraham Duarte

Dept. of Computer Sciences

Universidad Rey Juan Carlos

C/Tulipán, S/N, 28933, Móstoles, Spain

Email: abraham.duarte@urjc.es

**Abstract**—Community detection in social networks is becoming one of the key tasks in social network analysis, since it helps analyze groups of users with similar interests, detect radicalisms, or reduce the size of the data to be analyzed, among other applications. This paper presents a metaheuristic approach based on Greedy Randomized Adaptive Search Procedure methodology for detecting communities in social networks. The community detection is modeled as an optimization problem where the objective function to be optimized is the modularity of the network, a well known metric in community detection. The results obtained outperforms traditional methods of community detection as Edge Betweenness, Fast Greedy and Infomap over a set of real-life instances derived from Twitter.

## I. INTRODUCTION

The evolution of social networks in the last decades has aroused the interest of scientist from different and diverse areas, from psychology to computer sciences. Millions of people constantly share all their personal and professional information in several social networks. Furthermore, social networks have become one of the most used information sources, mainly due to their ability to provide the user with real-time content. Social networks are not only a new way of communication, but also a powerful tool that can be used to gather information related to several issues: which political party is the favourite for the next elections, what are the most commented movies in the last year, which is the best rated restaurant in a certain area, etc.

The analysis of social networks has become one of the most popular and challenging tasks in data science [1]. One of the most tackled problems in social networks is the analysis of the relevance of the users in a given social network. The relevance of a user is usually related to the number of followers or friends that the user has in a certain social network. However, this concept can be extended since a user may be relevant not only if he/she is connected with a large number of users, but with users that are also relevant. Several metrics have been proposed for analyzing the relevance of a user in a social network, emerging the PageRank [2] as one of the most used.

The problem of evaluating the relevance of a user has evolved in a more complex problem which consists of detecting specific users, often named influencers, with certain personal attributes that can be personal (credibility or enthusiasm) or related to their social networks (connectivity or centrality).

These attributes allow them to influence a large number of users either directly or indirectly [3].

Another important problem regarding the influence of people in other users is the analysis of sentiments in social networks. It is focused on finding out what do people think about a certain topic by analyzing the information they post in social networks. We refer the reader to [4] to find a complete survey on sentiment analysis techniques.

The previously described problems are related to individual users. However, there also exists some problems related to the structure of the network, devoted to find specific attributes and properties that can help to infer additional information of the social network. Community detection emerges as one of the most studied problems related to the structure of the network.

Most of the social networks present a common feature named community structure. Networks that have this property has the capacity to be divided into groups in such a way that the connections among users in the same group are dense, while connections among users in different groups are sparse. A connection can represent different features depending on the social network and the user profile, from professional relationships to friendships or hobbies in common. Community detection tasks are devoted to find and analyze these groups in order to better understand and visualize the structure of network and the relationships among their users.

Performing community detection algorithms over current social networks requires from a huge computationally effort mainly due to the continuous growth of social networks. Furthermore, since social networks are constantly changing (new friendships, mentions to users, viral information, etc.), it is interesting to perform the community detection in the shortest possible computing time, producing real-time information. These features make traditional exact methods not suitable for the current size of social networks, requiring from approximation algorithms in order to accelerate the process without losing quality. Recent works have tackled the community detection algorithm from a non-exact perspective in order to generate high quality solutions in short computing time [5].

The growth of social networks complicates their representation and understanding. The communities of a social network usually summarizes the whole network but reducing

its size and, therefore, making it easier to analyze. Furthermore, detecting communities in social networks has several practical applications. Recommender systems leverage the data of similar users in order to suggest new contents. In order to find similar users in a network we can simply perform a community detection over the network [6], improving the results of the recommender system. Communities in social networks also identifies people with similar interests, allowing us to evaluate the popularity of a political party [7], or even to detect radicalisms in social networks [8].

The remaining of the paper is structured as follows: Section II formally defines the problem considered as well as the metrics proposed for the evaluation of solutions; Section III describes the traditional algorithms proposed for detecting communities in social networks; Section IV presents the new algorithm proposed for detecting communities; Section V shows the computational experiments performed to test the quality of the proposal; and finally Section VI draws some conclusions on the research.

## II. PROBLEM STATEMENT

A social network is represented as a graph  $G = (V, E)$ , where the set of vertices  $V$ , with  $|V| = n$ , represents the users of the network and the set of edges  $E$ , with  $|E| = m$ , represents relations between users belonging to the network. An edge  $(v_1, v_2) \in E$ , with  $v_1, v_2 \in V$  can represent different types of relations depending on the social network under consideration. For example, in Twitter a relation represents that a user follows / is followed by an other user, while in LinkedIn it represents a professional relationship.

This work is focused on the Community Detection Problem (CDP), which involves grouping users of a social network into clusters. A desirable community in a social network is densely connected to the nodes in the same community and sparsely connected (or even unconnected) to nodes in other communities. Therefore, the main objective is to obtain groups or clusters of users that are similar among them and, at the same time, different to the users in other clusters with respect to a certain criterion.

A solution for the CDP is represented by a set of decision variables  $S$ , with  $|S| = n$ , where  $S_v = j$  indicates that vertex  $v$  is assigned to cluster  $j$  in solution  $S$ . Figure 1(a) shows an example graph with 19 vertices and 31 edges derived from a social network. In this example, an edge represents a friendship relationship between two users; for instance, users A and B are friends, while users A and C are not friends but they have a friend in common, which is vertex D.

Figure 1(b) shows a possible solution  $S$  for the community detection problem, where each cluster is represented with a different color. Regarding the solution representation previously defined, we can check the cluster for each vertex. Table I shows the community in which each vertex has been inserted (for example, vertex A belongs to community 1, vertex G to community 2, and so on).

The CDP then can be modeled as an optimization problem which consists of finding a solution  $S^*$  that maximizes a certain objective function value. In mathematical terms,

$$S^* \leftarrow \arg \max_{S \in \mathbb{S}} f(S)$$

where  $\mathbb{S}$  is the set of all possible solutions for a given social network.

There exists a large variety of quality metrics that can be used as objective function for finding high quality solutions. Several metrics considers that the optimal partition (ground truth) is known beforehand, and tries to minimize the distance of the current partition with respect to the optimal one (e.g., Omega-Index [5]). However, this work considers networks where the optimal partition is not known. In this case, most of the metrics are focused on maximizing the density of intra-cluster edges (those connecting vertices of the same cluster) while minimizing inter-cluster edges (those connecting vertices in different clusters).

We consider two metrics that has been traditionally considered for optimizing the quality of a solution for the CDP: conductance and modularity [9]. For the sake of simplicity, all metrics are normalized in the range 0–1, where 1 indicates the value for the optimal partition and 0 is the expected score for a random assignment of users to clusters. Notice that in some of the metrics the optimal score of 1 is not possible for some networks due to their internal structure.

The first metric considered is the conductance [10]. Given a cluster  $k$ , its conductance,  $C_n(k, G)$ , is defined as the number of edges that connect vertices of different clusters divided by the minimum between the number of edges with an endpoint in the cluster and the number of edges with no endpoint in the cluster. A large value in the conductance indicates that there are several edges connecting vertices in different clusters and, therefore, the cluster does not represent a community. More formally,

$$\begin{aligned} C_n(k, G) &= \frac{|(v, u) \in E : S_v = k \wedge S_u \neq k|}{\min\{E_k, \overline{E}_k\}} \\ E_k &= |(v, u) \in E : S_v = k \vee S_u = k| \\ \overline{E}_k &= |(v, u) \in E : S_v \neq k \wedge S_u \neq k| \end{aligned}$$

Then, the conductance of a complete solution  $C_n(S, G)$  is evaluated as the average conductance for all the clusters in the graph. In order to have a direct comparison with other metrics, we subtract that value from 1, so the objective is again to maximize the opposite of the conductance  $\overline{C}_n(S, G)$  to produce high quality solutions (i.e.,  $\overline{C}_n(S, G) = 1 - C_n(S, G)$ ). Then, the opposite of the conductance value for the example depicted in Figure 1(b) is  $\overline{C}_n(S, G) = 0.63$ .

The third metric studied is the modularity [11], which evaluates, for each edge connecting vertices in the same cluster, the probability of the existence of that edge in a random graph. The modularity is evaluated as:

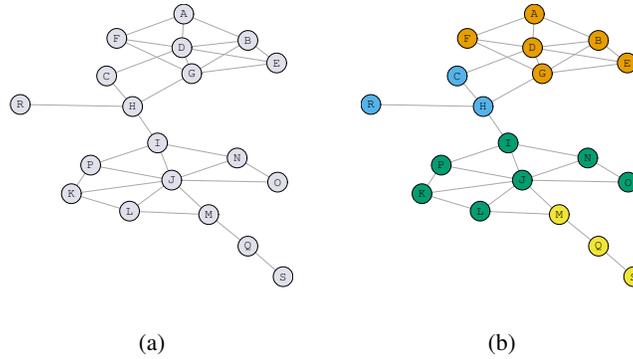


Fig. 1: 1(a) Example of a graph derived from a social network and 1(b) a possible solution for the community detection (each community is represented with a different color).

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
1	1	1	1	1	1	2	2	3	2	3	3	3	3	3	4	3	4	4

TABLE I: Cluster assigned to each vertex in the solution depicted in Figure 1(b).

$$Md(S, G) = \sum_{j=1}^{\max(S)} (e_{jj} - a_j^2)$$

$$e_{jj} = \frac{|\{(v, u) \in E : S_v = S_u = j\}|}{|E|}$$

$$a_j = \frac{|\{(v, u) \in E : S_v = j\}|}{|E|}$$

where  $\max(S)$  is the maximum value for the  $S_i$  variables, which corresponds to the number of clusters in the solution. The majority of the traditional algorithms for community detection considers this metric as the one to be optimized in order to find high quality communities. The modularity value for the graph depicted in Figure 1(b) is  $Md(S, G) = 0.50$ .

### III. ALGORITHMS FOR COMMUNITY DETECTION

Several algorithms has been proposed for detecting communities in social networks. Community detection algorithms can be classified in two different classes: agglomerative or divisive clustering. On the one hand, agglomerative methods starts from a solution where each vertex is located in a different cluster and tries to optimize a given objective function by joining two or more communities at each step. On the other hand, divisive methods starts from a solution with all the vertices located in a single cluster, and the objective function is optimized by dividing one or more clusters in each step. Most of the algorithms are not exact procedures, since in most of the networks it is not feasible to find the optimal solution in a reasonable time, mainly due to the number of users in the network. This Section is devoted to describe the most used algorithms in the state of the art for the CDP, in order to have a framework of comparison for the algorithm presented in this work.

#### A. Edge-Betweenness

The idea of the Edge-Betweenness algorithm [12] relies on identifying those vertices that appears in the majority of the paths in the graph. Specifically, authors define the edge betweenness of an edge as the number of shortest paths between pairs of vertices that contains the edge under evaluation. Therefore, groups or communities are generated by removing the edge with the largest edge betweenness value in each step. This algorithm presents a complexity of  $O(m^2n)$ .

#### B. Fast-Greedy

The Fast-Greedy algorithm [13] is focused on optimizing the modularity of the solutions generated. This agglomerative method starts from a solution where each vertex is located in a different cluster and iteratively join the two clusters that produce the solution with maximum modularity value. The optimization and data structures presented in the original work reduces the complexity of the algorithm to  $O(n \cdot m \cdot \log n)$ .

#### C. Infomap

The Infomap algorithm [14] proposed a fast stochastic and recursive search method which is based on joining neighbor vertices into the same community. The method starts with each vertex located in a different community. Then, it randomly selects a vertex and assigns it to the community that minimizes the map equation. The map equation is presented in this work and it is an efficient estimation of the optimality of a certain partition. Then, the method creates a new network where the new vertices are the communities detected until now. The algorithm stops when no changes are produced in the communities.

#### D. Evaluation of the previous methods

This Section is devoted to evaluate the results obtained by the different methods over an example graph that presents community structure [15]. Figure 2 illustrates the graphical

results over the community detection in the graph, where each community is represented with a different color.

As it can be seen, the results are different for each algorithm. Additionally, Table II presents the results obtained by each considered algorithm over the example graph depicted in Figure 2, considering the three metrics described in Section II and the number of communities found.

First of all, we will analyze the modularity metric, since it is the most used metric in community detection optimization. The best results in modularity corresponds to the Fast Greedy (0.5284) algorithm, closely followed by Edge Betweenness (0.5245) and InfoMap (0.5231). All the values are close since the considered algorithms are focused on optimizing the modularity.

Regarding the conductance, we can see that best results are obtained again with the Fast Greedy approach, closely followed by the Edge Betweenness algorithm. In this case, both Label Propagation and Infomap present worst results in term of conductance. These results suggest that optimizing one of the metrics does not guarantee a good result in the other considered ones.

Finally, analyzing the number of communities detected, most of the algorithms detect 6 communities, which seems to be the actual number of communities in the social network. The Label Propagation algorithms prematurely stops the search, resulting in only 4 communities, while the largest number of communities, 8, is found by Infomap algorithm.

#### IV. GREEDY RANDOMIZED ADAPTIVE SEARCH PROCEDURE

Greedy Randomized Adaptive Search Procedure (GRASP) is a metaheuristic originally presented in [16] and formally defined in [17]. We refer the reader to [18] for a recent survey on this methodology. This metaheuristic can be divided into two main phases: solution generation and local improvement.

The solution generation phase iteratively adds elements to an initially empty solution until it becomes feasible. The first element is usually selected at random, acting as a seed for the procedure. The algorithm then constructs a candidate list ( $CL$ ) with all the elements that must be included in the solution. After that, a Restricted Candidate List ( $RCL$ ) is created with the most promising elements of the  $CL$  according to a predefined greedy function. Then, in each iteration, an element is selected at random from the  $RCL$  and added to the solution under construction, updating the  $CL$  and  $RCL$  in each step until reaching a feasible solution.

The construction phase of the GRASP algorithm presents a random part devoted to increase the diversity of the solutions generated. In particular, in the previous description, the random part relies on the selection of the next element from the  $RCL$ . Therefore, most of the obtained solutions are not a local optimum and can be improved by means of a local optimizer. The second phase of the GRASP algorithm is intended to find a local optimum of the solution generated, usually applying a local search method, although it can be replaced with a more complex optimizer.

The algorithm presented in this section is able to optimize any of the metrics defined in Section I. However, since the algorithm considered for the comparison are focused on optimizing the modularity, the proposed algorithm is also focused on optimizing the modularity, which has been traditionally considered as a good optimization metric.

#### A. Constructive procedure

The constructive procedure designed for the community detection problem, named *GRASPAGG* follows an agglomerative approach, where each element is initially located in a different cluster. Then, *GRASPAGG* iteratively joins two of the most promising clusters with the objective of maximizing one of the aforementioned metrics. Algorithm 1 shows the pseudocode of the *GRASPAGG* constructive method.

---

#### Algorithm 1 *GRASPAGG*( $G, \alpha$ )

---

```

1:  $S_v \leftarrow v \forall v \in V$ 
2:  $CL \leftarrow \{1, 2, \dots, n\}$ 
3:  $continue \leftarrow \mathbf{True}$ 
4: while  $continue$  do
5:    $continue \leftarrow \mathbf{False}$ 
6:    $g_{\min} \leftarrow \min_{j \in CL} (e_{jj} - a_j^2)$ 
7:    $g_{\max} \leftarrow \max_{j \in CL} (e_{jj} - a_j^2)$ 
8:    $\mu \leftarrow g_{\min} + \alpha \cdot (g_{\max} - g_{\min})$ 
9:    $RCL \leftarrow \{j \in CL : (e_{jj} - a_j^2) \geq \mu\}$ 
10:   $j_1 \leftarrow \mathit{Random}(RCL)$ 
11:   $Md_{best} \leftarrow Md(S, G)$ 
12:   $j_2 \leftarrow -1$ 
13:  for  $j' \in 1 \dots CL$  do
14:     $S' \leftarrow S$ 
15:     $S'_v \leftarrow j_1 \forall S_v = j'$ 
16:    if  $Md(S', G) > Md_{best}$  then
17:       $Md_{best} \leftarrow Md(S', G)$ 
18:       $continue \leftarrow \mathbf{True}$ 
19:       $j_2 \leftarrow j'$ 
20:    end if
21:  end for
22:  if  $continue$  then
23:     $S_v \leftarrow j_1 \forall S_v = j_2$ 
24:     $CL \leftarrow CL \setminus \{j_2\}$ 
25:  end if
26: end while
27: return  $S$ 

```

---

The method starts by assigning a different cluster to each node in the graph  $G$  (step 1). Then, the  $CL$  is constructed with every cluster in the solution  $S$  under construction (step 2). Then, the minimum ( $g_{\min}$ ) and maximum ( $g_{\max}$ ) values for the greedy function under evaluation are calculated (steps 6-7). The proposed greedy function is the modularity value of each cluster  $j$ , which is  $e_{jj} - a_j^2$ , as stated in Section II. Then, a threshold  $\mu$  is evaluated (step 8) to construct the  $RCL$  with the most promising candidates in  $CL$  (step 9). The next steps selects the two clusters that will be merged in the current iteration, being the first cluster  $j_1$  to be merged selected at

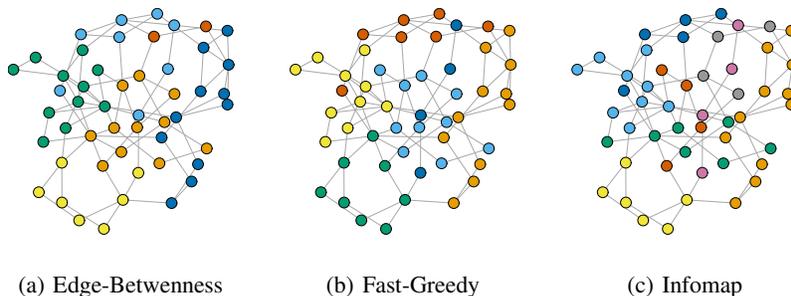


Fig. 2: Comparison of the community detection of the described algorithms over a example graph with 50 nodes that presents community structure.

TABLE II: Evaluation of the solution generated by each algorithm over the example graph using the three considered metrics

Algorithm	Modularity	Coverage	Conductance	Number of communities
Edge Betweenness	0.5245	0.7250	0.5248	6
Fast Greedy	0.5284	0.7125	0.5306	6
Infomap	0.5231	0.6750	0.4732	8

random from the *RCL* (step 10). The second cluster  $j_2$  is the one that maximizes the modularity of the resulting solution after merging clusters  $j_1$  and  $j_2$  (steps 11-21). If the method has found an improvement in the modularity after joining both clusters, a new iteration is performed, updating the incumbent solution (step 23) and the candidate list (step 24). *GRASPAGG* stops when it is not possible to join two clusters improving the modularity, returning the best solution found.

### B. Local optimization

This section presents a local search procedure designed to find a local optimum for every solution constructed in the previous phase. In order to define a local search method we firstly need to define the neighborhood in which the local optimum will be found. For this problem, we consider all the solutions that can be reached from a given solution  $S$  by moving a node from one cluster to another. Specifically, after performing the move  $Move(S, v, j)$ , the vertex  $v$  will be located at cluster  $j$  (i.e.,  $S_v \leftarrow j$ ). Notice that if  $v$  was the last vertex in its original cluster  $j'$ , then cluster  $j'$  will disappear after performing the move.

The next step for defining the local search method is the selection of the vertex to be moved to another community. For this purpose, we define a heuristic criteria based on the number of intra-cluster edges of the vertex under evaluation with respect to the total number of edges in the graph. Specifically, the local search selects the vertex  $v$  with the smallest ratio  $r$  between number of edges in the same cluster and the total number of incident edges to  $v$ . More formally,

$$r(v, S) \leftarrow \frac{|(v, u) \in E : S_v = S_u|}{|(v, w) \in E|} \quad \forall u, w \in V$$

The local search method selects, for each community, the node with the smallest value of this selection criteria among all nodes in the graph. Then, the node is moved to the

community that maximizes the modularity among all the existing communities in the incumbent solution.

The proposed local search procedure follows a first improvement approach. In particular, the first improvement move found is performed, restarting the search again, opposite to performing the best available move, which is often rather time consuming. The method stops when no improvement is found after evaluating the move of a node in every community.

### V. COMPUTATIONAL RESULTS

This Section is devoted to analyze the quality of the proposed algorithm when compared with the most popular community detection algorithms presented in Section III. Since most of the algorithms are focused on optimizing the modularity, the evaluation of the quality must be performed over a different metric. In this work we consider conductance as the evaluation metric, for testing the robustness of the methods. We additionally include the modularity value obtained by each algorithm, although it should not be considered in the evaluation of the quality of the community detection. However, we consider that it is interesting to analyze how far an algorithm is able to optimize the detection considering the modularity value. The proposed algorithm have been implemented in Java 8 and the experiments have been conducted in an Intel Core 2 Duo E7300 2.66 GHz with 4 GB RAM.

The instances used for the experiment have been extracted from the Twitter SNAP dataset<sup>1</sup>. Specifically, we have selected 100 instances with vertices ranging from 50 to 250, that represents the ego-network of several Twitter users (data is anonymized in the dataset).

The first experiment is devoted to tune the  $\alpha$  parameter of the *GRASPAPP* procedure. This parameter controls the degree of randomness of the method: on the one hand,  $\alpha = 0$  results in a totally random method, while  $\alpha = 1$  considers

<sup>1</sup><https://snap.stanford.edu/data/egonets-Twitter.html>

a completely greedy method. Therefore, it is interesting to test values distributed in the range 0–1 to analyze whether the best results for the CDP are obtained with a small or large percentage of randomness in the construction. In this experiment we have considered  $\alpha = \{0.25, 0.50, 0.75, RND\}$ , where *RND* indicates that a random value of  $\alpha$  is selected for each construction. This experiment has been conducted over a subset of 20 representative instances in order to avoid overfitting.

Table III reports the results obtained with the different values of  $\alpha$ . Specifically, three statistics are considered: Modularity, the average of the best modularity value obtained for each instance; Dev (%) the average deviation with respect to the best solution found in the experiment; and #Best, the number of times that an algorithm reaches that best solution.

TABLE III: Results obtained by the GRASP algorithm considering different values for  $\alpha$  parameter

$\alpha$	Modularity	Dev (%)	#Best
0.25	0.31961	1.60	9
0.50	0.32019	1.30	5
0.75	0.32063	1.08	4
RND	0.32080	1.08	6

As it can be derived from Table III, the best results are obtained with  $\alpha = 0.75$ . In particular, is able to obtain the best modularity values and reaches the best solution in 9 out of 20 instances. The average deviation value of 0.65% indicates that, in those instances in which it is not able to reach the best value, it remains rather close to it. Therefore, we select  $\alpha = 0.75$  for the final experiment.

The final experiment is intended to compare the quality of the solutions provided by our proposal with respect to the traditional methods described in Section III.

TABLE IV: Comparison of the considered metrics over all the algorithms presented in Section III and the proposed GRASP method.

	Modularity	Conductance
EB	0.14272	0.11319
FG	0.25064	0.34494
IM	0.14216	0.33014
GRASP	0.26029	0.38206

These results show the superiority of the proposal when considering both modularity and conductance, supported by a *p*-value lower than 0.0001 when applying the Friedman statistical test.

## VI. CONCLUSIONS

This paper has proposed a new metaheuristic method for community detection in social network based on Greedy Randomized Adaptive Search Procedure methodology. The problem is addressed by optimizing the modularity metric, which is a robust metric to evaluate the quality of a partition in a social network. The algorithm is compared with several well-known traditional algorithms for community detection using

conductance as evaluation metric. The computational results show how GRASP is able to obtain better results in both metrics than the previous methods, emerging as a competitive algorithm for detecting communities in social networks.

## ACKNOWLEDGMENT

This work has been partially funded by Ministerio de Economía y Competitividad with grant ref. TIN2015-65460-C2-2-P.

## REFERENCES

- [1] S. N. Dorogovtsev and J. F. F. Mendes, *Evolution of Networks: From Biological Nets to the Internet and WWW*. Oxford University Press, Oxford, 2003.
- [2] L. Page, S. Brin, R. Motwani, and T. Winograd, "The PageRank citation ranking: Bringing order to the web." Stanford InfoLab, Tech. Rep., 1999.
- [3] M. Gladwell, *The Tipping Point How Little Things Can Make a Big Difference*. Boston: Little Brown and Company, 2000.
- [4] B. Pang and L. Lee, "Opinion mining and sentiment analysis," *Foundations and Trends in Information Retrieval*, vol. 2, no. 1-2, pp. 1–135, 2008.
- [5] A. González-Pardo, J. J. Jung, and D. Camacho, "ACO-based clustering for Ego Network analysis." *Future Generation Comp. Syst.*, vol. 66, pp. 160–170, 2017.
- [6] C. Cao, Q. Ni, and Y. Zhai, "An Improved Collaborative Filtering Recommendation Algorithm Based on Community Detection in Social Networks." in *GECCO*, S. Silva and A. I. Esparcia-Alcázar, Eds. ACM, 2015, pp. 1–8.
- [7] N. Zalmout and M. Ghanem, "Multidimensional community detection in Twitter." in *ICITST*. IEEE, 2013, pp. 83–88.
- [8] D. Camacho, A. González-Pardo, A. Ortigosa, I. Gilpérez-López, and C. Urruela, "RiskTrack: A New Approach for Risk Assessment on Radicalisation Based on Social Media Data." in *AfCAI*, ser. CEUR Workshop Proceedings, M. T. H. Ezquerro, G. J. Nalepa, and J. T. P. Mendez, Eds., vol. 1794. CEUR-WS.org, 2016.
- [9] S. Emmons, S. Kobourov, M. Gallant, and K. Börner, "Analysis of Network Clustering Algorithms and Cluster Quality Metrics at Scale," *PLoS ONE*, vol. 11, no. 7, 2016.
- [10] H. Almeida, D. O. G. Neto, W. M. Jr., and M. J. Zaki, "Is There a Best Quality Metric for Graph Clusters?" in *ECML/PKDD (1)*, ser. Lecture Notes in Computer Science, D. Gunopulos, T. Hofmann, D. Malerba, and M. Vazirgiannis, Eds., vol. 6911. Springer, 2011, pp. 44–59.
- [11] M. E. J. Newman and M. Girvan, "Finding and evaluating community structure in networks," *Physical Review*, vol. E 69, no. 026113, 2004.
- [12] M. Girvan and M. E. J. Newman, "Community structure in social and biological networks," *PNAS*, vol. 99, no. 12, pp. 7821–7826, 2002.
- [13] A. Clauset, M. E. J. Newman, and C. Moore, "Finding community structure in very large networks," *Physical Review E*, vol. 70, p. 066111, 2004.
- [14] M. Rosvall, D. Axelsson, and C. T. Bergstrom, "The map equation," *The European Physical Journal Special Topics*, vol. 178, no. 1, pp. 13–23, 2009.
- [15] A. Lancichinetti, S. Fortunato, and F. Radicchi, "Benchmark graphs for testing community detection algorithms," *Phys. Rev. E*, vol. 78, no. 4, p. 046110, 2008.
- [16] T. A. Feo and M. G. C. Resende, "A probabilistic heuristic for a computationally difficult set covering problem," *Operations Research Letters*, vol. 8, no. 2, pp. 67 – 71, 1989.
- [17] T. A. Feo, M. G. C. Resende, and S. H. Smith, "A Greedy Randomized Adaptive Search Procedure for Maximum Independent Set." *Operations Research*, vol. 42, no. 5, pp. 860–878, 1994.
- [18] M. G. C. Resende and C. C. Ribeiro, *GRASP: Greedy Randomized Adaptive Search Procedures*. Boston, MA: Springer US, 2014, pp. 287–312.



# Analizando la influencia de los atentados del 11-M en las elecciones generales de 2004: un enfoque ABM

Ignacio Moya\*, Manuel Chica\*, José L. Sáez-Lozano †, Oscar Cordón\*

\*Instituto Andaluz Interuniversitario DaSCI (Data Science and Computational Intelligence), Universidad de Granada

† Departamento de Economía Internacional y de España y GIADE-UGR, Universidad de Granada

Emails: imoya@ugr.es, manuelchica@ugr.es, josaez@ugr.es, ocordova@decsai.ugr.es

El 11 de marzo de 2004 (11-M), tres días antes de las elecciones generales del 14 de marzo, un grupo de terroristas detonó varios explosivos en trenes que se dirigían a la estación de Atocha en Madrid. 193 personas perdieron la vida y cerca de 2000 resultaron heridas. Los atentados alteraron el proceso electoral: la mañana del 11-M se suspendió la campaña; el 12 de marzo hubo manifestaciones contra el terrorismo en las principales ciudades españolas; el 13 de marzo hubo una manifestación frente a la sede del Partido Popular (PP), el partido en el gobierno en aquel momento. Finalmente las elecciones trajeron un inesperado cambio de gobierno.

Tras los atentados se generó una cantidad de información por parte del gobierno, políticos, y medios de información, forzando a los candidatos a posicionarse con respecto a los atentados. Una posición que los votantes incorporarían a su decisión de voto [1]. Este evento tuvo un marco comunicativo que se estructuró entorno a dos framings: la autoría de los atentados por parte de ETA o Al'Qaeda. La primera era la posición defendida por el gobierno del PP, mientras que el principal partido de la oposición, el Partido Socialista Obrero Español (PSOE), y otras fuerzas políticas defendían la segunda [2]. Muchos votantes evaluaban positivamente la gestión del PP en la lucha contra ETA, por lo que el presidente Aznar declaró a ETA responsable de los atentados del 11-M como estrategia electoral [3]. Por contra, la decisión del gobierno de participar en la invasión de Irak iba contra gran parte de la opinión pública y el resto de partidos políticos.

Distintos estudios postelectorales muestran que los atentados del 11-M influyeron en los votantes [3], [4], [5]. La interpretación más común es que el resultado de las elecciones fue un castigo al partido del gobierno tanto por su gestión de los atentados como por su política exterior. Aun así, no existen estudios anteriores que expliquen el efecto framing en la decisión electoral. Chong y Druckman [6] definen el efecto framing como el proceso psicológico que permite a las personas desarrollar una conceptualización *ad hoc* de un evento, ajustando su opinión en consecuencia. Según el CIS, el 11% de los votantes cambiaron su voto tras los atentados [7].

Dada la importancia socio-económica y política de estos hechos en la historia reciente de España, nuestro objetivo es analizar el efecto framing generado tras los atentados y su influencia en la decisión de quienes tenían la intención de

votar al PP, al PSOE, o abstenerse tras los atentados. Ello nos permitirá conocer la influencia del tratamiento mediático de la responsabilidad de los atentados y la difusión por boca a boca (WOM) [8], [9]. Modelamos este escenario empleando *agent-based modeling* (ABM) [10], [11], dado que ya ha sido aplicada con éxito en otros escenarios políticos [12], [13]. La metodología ABM utiliza una población de entidades autónomas (agentes) que siguen reglas simples y tienen la capacidad de interactuar entre ellos. La agregación de ambos permiten representar dinámicas emergentes y definir escenarios *what-if*.

De este modo simulamos las 72 horas siguientes a los atentados y estudiamos como la información que se difunde durante este periodo de tiempo afecta a la población hasta llegar el momento de la votación. Segmentamos la población de agentes usando datos pre-electorales para replicar las principales opciones políticas: PP, PSOE, y abstención. Nuestro *framework* de simulación también reproduce la información de los medios y del WOM usando redes sociales artificiales [14]. Modelamos WOM difundiendo las percepciones de los votantes [8] a través de una red libre de escalas [14]. Respecto a los medios de información elegidos, tomamos los de mayor audiencia en esa época (i.e., televisión, radio, y prensa).

Usando datos pre-electorales reales como entrada, validamos nuestro diseño para ajustar su comportamiento a los resultados de las elecciones, calibrando algunos de sus parámetros tomando como objetivo el resultado de las elecciones. Aunque los valores de algunos parámetros se ajustan directamente usando datos reales de confianza, otros son más difíciles de estimar y deben ser ajustados usando calibración automática (como los parámetros que regulan la difusión de WOM y la influencia de los medios). En concreto, nuestra estrategia de calibración usa un algoritmo memético [15] basado en un algoritmo genético [16] y una búsqueda local, obteniendo un ajuste del 99.13%. En la Figura 1 mostramos la evolución de votos de nuestro modelo para cada día de este periodo.

Definimos distintos experimentos donde observamos cómo los medios y el WOM influyen a los votantes a través de sus agentes correspondientes en el modelo calibrado. Estos experimentos son escenarios *what-if* donde analizamos comunicaciones alternativas de los medios y del WOM. Las alternativas para los medios suponen alterar el mensaje original para favorecer uno u otro marco. En el caso del WOM,

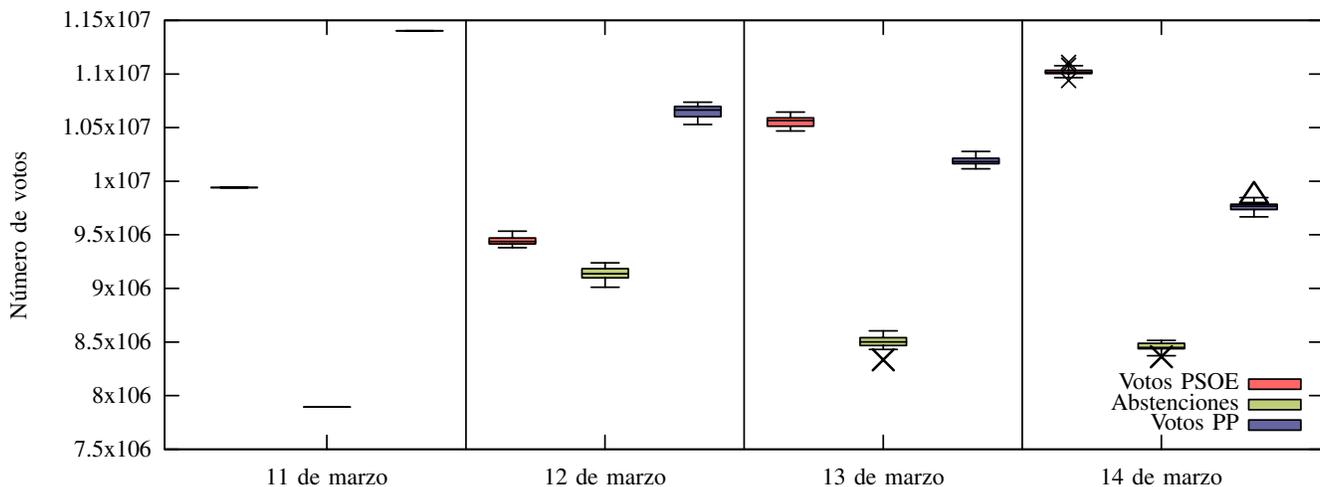


Figura 1: Promedio de votos por opción política para cada día entre los atentados y las elecciones.

los escenarios consideran comportamientos alternativos que modifican cómo los votantes reaccionan a la difusión de percepciones políticas. De este modo, monitorizamos el resultado de las elecciones para cada escenario.

Los resultados de los experimentos sugieren que el efecto marco pudo efectivamente influir en las elecciones movilizándolo abstencionistas y desactivando votantes del PP. En este punto podemos resaltar que los mecanismos de difusión tienen un papel muy importante durante este periodo, dado que aparece un gran intercambio de votos al modificar la densidad de la red social o la probabilidad de difusión. Esto a su vez es consistente con otros trabajos que tratan la difusión de percepciones políticas [17], [18]. También podemos observar que la red social tiene un papel importante al exponer a los agentes a mensajes altamente polarizados.

Los resultados también reflejan que la agregación de los medios de comunicación consigue un efecto mayor que la suma individual de los medios. Incluso si la televisión se distingue claramente como el medio más influyente, radio y prensa incrementan el efecto agregado de manera notable. Esto no solo resalta que la televisión tuvo un papel importante en la difusión de información durante este periodo, sino que la presencia de otros medios fue decisiva para los resultados de las elecciones.

#### AGRADECIMIENTOS

Este trabajo está financiado por el Ministerio de Economía y Competitividad bajo el proyecto NEWSOCO (ref. TIN2015-67661-P), incluyendo Fondos Europeos de Desarrollo Regional (ERDF).

#### REFERENCIAS

- [1] T. Holbrook, *Do campaigns matter?* Contemporary American Politics. SAGE publications, 1996.
- [2] J. A. Olmeda, "Fear or falsehood? Framing the 3/11 terrorist attacks in Madrid and electoral accountability," *Boletín Elcano*, no. 70, 2005.

- [3] I. Lago and J. R. Montero, *The 2004 election in Spain: Terrorism, accountability, and voting*. Barcelona: Institut de Ciències Polítiques i Socials, 2006.
- [4] I. Lago Peñas, J. R. Montero, and M. Torcal, "Del 11-M al 14-M: Los mecanismos del cambio electoral," *Claves de la razón práctica*, vol. 149, pp. 36–45, 2005.
- [5] V. A. Bali, "Terror and elections: Lessons from Spain," *Electoral Studies*, vol. 26, no. 3, pp. 669–687, 2007.
- [6] D. Chong and J. N. Druckman, "Framing theory," *Annual Review of Political Science*, vol. 10, pp. 103–126, 2007.
- [7] Centro de Investigaciones Sociológicas, "Estudio 2555," CIS Data bank, 2004.
- [8] D. Duzevik, A. Anev, P. Funes, and P. Gaudiano, "The effects of word-of-mouth: An agent-based simulation of interpersonal influence in social networks," *Word of Mouth Research Symposium*, 2007.
- [9] B. Libai, E. Muller, and R. Peres, "Decomposing the value of word-of-mouth seeding programs: Acceleration versus expansion," *Journal of Marketing Research*, vol. 50, no. 2, pp. 161–176, 2013.
- [10] E. Bonabeau, "Agent-based modeling: Methods and techniques for simulating human systems," *Proceedings of the National Academy of Sciences*, vol. 99, no. suppl 3, pp. 7280–7287, 2002.
- [11] J. M. Epstein, *Generative social science: Studies in agent-based computational modeling*. Princeton University Press, 2006.
- [12] M. Laver, "Policy and the dynamics of political competition," *American Political Science Review*, vol. 99, no. 02, pp. 263–281, 2005.
- [13] J. Muis, "Simulating political stability and change in the netherlands (1998-2002): an agent-based model of party competition with media effects empirically tested," *Journal of Artificial Societies and Social Simulation*, vol. 13, no. 2, p. 4, 2010.
- [14] A. L. Barabási and R. Albert, "Emergence of scaling in random networks," *Science*, vol. 286, no. 5439, pp. 509–512, 1999.
- [15] P. Moscato, "On evolution, search, optimization, genetic algorithms and martial arts: towards memetic algorithms," Caltech Concurrent Computation Program, Pasadena, USA, Tech. Rep. 826, 1989.
- [16] T. Back, D. B. Fogel, and Z. Michalewicz, *Handbook of evolutionary computation*. Bristol (UK): IOP Publishing Ltd., 1997.
- [17] V. K. Singh, S. Basak, and N. Modanwal, "Agent based modeling of individual voting preferences with social influence," in *Trends in Computer Science, Engineering and Information Technology*. Springer, 2011, pp. 542–552.
- [18] Y. Sudo, S. Kato, and A. Mutoh, "The impact of exchanging opinions in political decision-making on voting by using multi-agent simulation," in *PRIMA 2013: Principles and Practice of Multi-Agent Systems*. Springer, 2013, pp. 340–354.



# Análisis de la influencia de los sentimientos en el proceso de detección de tópicos en redes sociales

Karel Gutiérrez-Batista  
Departamento de Ciencias de la  
Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
karel@decsai.ugr.es

Jesús R. Campaña  
Departamento de Ciencias de la  
Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
jesuscg@decsai.ugr.es

Maria-Amparo Vila  
Departamento de Ciencias de la  
Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
vila@decsai.ugr.es

Maria J. Martín-Bautista  
Departamento de Ciencias de la  
Computación e Inteligencia Artificial  
Universidad de Granada  
Granada, España  
mbautis@decsai.ugr.es

**Resumen**—En el presente trabajo se propone realizar un estudio para analizar la influencia que tienen los términos que expresan sentimientos en la detección automática de tópicos en redes sociales. Esta propuesta utiliza una metodología basada en una ontología, a la cual se le incorpora la capacidad de identificar y eliminar aquellos términos que presenten una orientación sentimental en textos de redes sociales, los cuales pueden influir de forma negativa en la detección de tópicos. Para ello se han utilizado dos recursos orientados al análisis de sentimientos con el fin de detectar dichos términos. El sistema propuesto ha sido evaluado con conjuntos de datos reales de las redes sociales Twitter y DreamChatchers en inglés y español respectivamente, demostrando en ambos casos la influencia de los términos con orientación sentimental en la detección de tópicos en textos de redes sociales.

**Palabras Claves**—Detección tópicos, Agrupamiento jerárquico, Etiquetado grupos, Términos sentimientos, Multilingüe

## I. INTRODUCCIÓN

Hoy día es un hecho reconocido el crecimiento y la popularidad alcanzada por las redes sociales, y como consecuencia de ello, el aumento del número de usuarios interactuando en dichas redes, lo que provoca la acumulación de grandes volúmenes de datos textuales no estructurados. Por tal motivo, las redes sociales constituyen una fuente de información de gran importancia, por lo que es de esperar que organizaciones, investigadores, etc., empleen tiempo y recursos en el estudio de estas. Sin embargo, el gran cúmulo y la falta de estructura de los textos, hace que sea prácticamente imposible su procesamiento y análisis automático de forma masiva, motivo por el cual resulta conveniente tener los textos previamente organizados teniendo en cuenta la temática abordada.

La detección de tópicos a partir de textos no estructurados, permite organizar dichos textos por temáticas, lo cual facilita su posterior análisis integrado con datos convencionales. En

[1] se ha propuesto una metodología multilingüe para la detección automática de tópicos en datos textuales. Mediante la experimentación, se demostró la viabilidad de la propuesta, aunque se debe resaltar que los resultados no son lo suficientemente buenos cuando los textos provienen de redes sociales.

Esto se debe a que la detección de tópicos en textos más elaborados (librerías digitales, sitios web de noticias, etc.) es diferente cuando los textos pertenecen a redes sociales. En dichos sistemas los usuarios expresan ideas, hechos y sentimientos sobre cualquier tema utilizando un lenguaje coloquial, por lo que es de esperar que en los textos aparezcan con alta frecuencia términos que permiten expresar sentimientos relacionados con determinados productos, servicios, etc.

Motivado por la problemática anterior, en este artículo se realiza un estudio para analizar la influencia de los términos que expresan sentimientos en la detección automática de tópicos en redes sociales. Para ello se propone un nuevo enfoque para mejorar la metodología para la detección automática de los principales tópicos presentes en datos textuales propuesta en [1], la cual utiliza técnicas de minería de datos, recursos relacionados con el análisis de sentimientos, y una base de conocimiento multilingüe. La nueva propuesta permite identificar y eliminar los términos con orientación sentimental, con el objetivo de mejorar los resultados del sistema sobre textos de redes sociales.

La idea básica consiste en realizar un filtrado que elimine las palabras que expresen sentimientos durante la etapa de preprocesamiento semántico presente en la metodología. Para ello, se utilizan los recursos léxicos SentiWordNet [2] y WordNet Affect [3] por separado y juntos, para luego comparar los resultados obtenidos. Para la experimentación se han utilizado cuatro conjuntos de datos, los cuales pertenecen a las redes sociales Twitter y Dreamcatchers, en inglés y español

respectivamente.

El resto de este artículo está estructurado de la siguiente forma. Se presenta una revisión de los trabajos previos relacionados con el presente tema en la Sección 2. La Sección 3 describe brevemente la propuesta seleccionada para la detección automática de tópicos. La Sección 4, brinda una descripción detallada del proceso principal que permite analizar la influencia de los términos que expresan sentimientos en la detección automática de tópicos en datos textuales de redes sociales. Seguidamente la Sección 5 presenta los resultados experimentales. Finalmente se presentan las conclusiones, así como los trabajos futuros derivados de la presente investigación en la Sección 6.

## II. ANTECEDENTES

La detección de tópicos a partir de grandes volúmenes de textos, ha sido un tema ampliamente analizado en la literatura desde varios puntos de vista. Entre ellos destaca el uso de métodos tales como algoritmos de clasificación, Latent Dirichlet Allocation (LDA) y algoritmos de agrupamiento, entre otros. Para el caso de los algoritmos de clasificación es necesario contar con un conjunto de datos de entrenamiento que permita entrenar el clasificador, mientras tanto LDA y los algoritmos de agrupamiento no resulta necesario contar con un corpus previamente clasificado.

Son muchos los trabajos que podemos encontrar relacionados con la detección de tópicos mediante el uso de algoritmos de agrupamiento jerárquico supervisados y semi-supervisados, no así para los no supervisados. Tales son los casos propuestos en [4]–[6], donde los autores proponen enfoques basados en el uso de información experta, para de esta forma mejorar los resultados en la detección de los principales tópicos.

Desde el punto de vista no supervisado, en [1] se presenta una propuesta para la detección automática de tópicos en datos textuales basada en ontologías. Se utilizó el recurso léxico WordNet Domains [7] con el fin de homogeneizar la representación sintáctica de los conceptos presentes en los textos y así reducir considerablemente la dimensionalidad del problema. Para la experimentación se empleó el conjunto de datos Reuters-21578 el cual contiene textos relacionados con publicaciones de noticias. Los resultados muestran la viabilidad de la propuesta, donde los valores del Coeficiente de Silueta son mejores cuando se aplica la metodología propuesta.

Se debe destacar que aunque los textos de Reuters-21578 constituyen datos reales, son textos largos, están bien elaborados y además pertenecen a un dominio restringido. Si tenemos en cuenta que los textos presentes en redes sociales son textos cortos y los usuarios principalmente expresan sus sentimientos sobre un tema determinado, dichos textos deberían ser preprocesados de forma diferente con el fin de extraer los tópicos presentes.

En redes sociales, la detección de tópicos ha sido extensamente utilizada para el análisis de datos textuales. Muchas han sido las soluciones que han aparecido para el análisis textual en redes sociales, tales como el análisis de sentimientos [8], el filtrado de contenidos [9], [10], el modelado de los

intereses del usuario [11], así como el seguimiento de eventos de interés [4], [12]. En [13] se realiza una comparación entre el contenido de los textos de Twitter con un medio de comunicación tradicional, el New York Times. Para ello se utiliza el modelado de tópicos sin supervisión utilizando el modelo Twitter-LDA, para descubrir dichos tópicos en mensajes cortos.

Por otra parte, son varios los trabajos que presentan un modelo donde se fusionan la detección y análisis de tópicos con el análisis de sentimientos [14]–[18]. En todos ellos la detección de tópicos se lleva a cabo sin tener en cuenta la influencia que tienen los términos con determinada orientación sentimental en dicha tarea.

En el presente trabajo se analiza la influencia de los términos con orientación sentimental en la detección de tópicos en redes sociales. Para ello se aplica un filtro durante el preprocesamiento semántico con el objetivo de eliminar los términos que expresan sentimientos, los cuales pueden introducir ruido en la detección de tópicos. Esta propuesta es totalmente novedosa ya que a diferencia de los trabajos mencionados donde se fusiona la detección de tópicos con el análisis de sentimientos, en este caso lo que se hace es descartar los términos de sentimientos, permaneciendo sólo los términos que aportan información útil para la detección automática de los principales tópicos.

## III. DESCRIPCIÓN DE LA PROPUESTA PARA LA DETECCIÓN DE TÓPICOS

Como se mencionó anteriormente, en este artículo se analiza la influencia de los términos con orientación sentimental en la detección automática de tópicos en redes sociales. Teniendo en cuenta que los datos textuales de redes sociales se encuentran escritos de una manera más coloquial, y los usuarios tienden a expresar sus sentimientos y opiniones sobre determinados productos, servicios, entidades, atributos de estos, etc., resulta útil detectar y eliminar aquellos términos con una determinada orientación sentimental, ya que dichos términos no aportan información útil para la detección de tópicos.

A continuación, se presenta un resumen de cada una de las fases del sistema propuesto, para más detalles ver [1]. Para el caso específico de la fase de Preprocesamiento semántico, se ha resaltado el filtro que permite identificar y descartar los términos de sentimientos, el cual constituye el principal aporte del presente trabajo, y será explicado detalladamente en la Sección IV.

### *Preprocesamiento sintáctico*

Una de las fases fundamentales en la detección de tópicos es el preprocesamiento sintáctico, el cual consiste en una limpieza sintáctica donde se aplican filtros a los datos textuales para facilitar su procesamiento automático. Primero, son ejecutados los procesos de etiquetado de categoría gramatical y de reconocimiento de entidades, dichos procesos se realizan con las herramientas Stanford POS [19] y Stanford NER respectivamente [20]. Luego se aplica el filtro de tokenización y los filtros necesarios para eliminar los términos que pertenecen al conjunto de palabras vacías, los que no son identificados



como sustantivos por el etiquetador gramatical, los que son identificados como sustantivos propios por el identificador de entidades, así como los aquellos términos que no se encuentren en la base de conocimiento Multilingual Central Repository (MCR) [21], ya que todos ellos no aportan información útil para la detección de los tópicos.

#### *Preprocesamiento semántico*

Una vez que los textos han sido preprocesados sintácticamente, se procede con el análisis semántico. En nuestro caso, el objetivo del preprocesamiento semántico, es el de homogeneizar la representación sintáctica de los conceptos presentes en el texto. Lo que se hace es sustituir las etiquetas de WordNet Domains [7] con las que han sido etiquetados los sentidos de WordNet por los términos presentes en los textos originales. Como ya se ha mencionado, en este trabajo se desea analizar la influencia de los términos con orientación sentimental en detección de tópicos, por tal motivo en la Sección IV, se explica en profundidad el proceso relacionado con la identificación y eliminación de los términos con orientación sentimental.

#### *Agrupamiento Jerárquico*

Una vez homogeneizados los textos, se procede a realizar el agrupamiento jerárquico de los textos a partir de las etiquetas de WordNet Domain. Para representar las características se ha utilizado el enfoque propuesto en [1]. En este artículo sólo se analizará el algoritmo de agrupamiento jerárquico Complete Link utilizando como medida de similitud la distancia del coseno.

#### *Etiquetado de grupos*

Cuando termina la fase de agrupamiento, se realiza el proceso de selección de etiquetas de los grupos, la cual constituye una tarea de gran importancia, sobre todo en aplicaciones relacionadas con el análisis de datos, donde el usuario final necesita conocer de qué trata determinado grupo [22]. En el presente trabajo se ha utilizado la Media Aritmética para determinar las etiquetas más relevantes de cada grupo de textos.

### IV. INFLUENCIA DE LOS SENTIMIENTOS EN LA DETECCIÓN DE TÓPICOS

En esta sección se describe el principal aporte del presente trabajo, que consiste en detectar y descartar los términos con orientación sentimental (positiva o negativa) con el fin de mejorar la detección de tópicos.

#### *IV-A. Análisis de los términos de sentimientos en la detección de tópicos*

Para detectar los términos con orientación sentimental, se han utilizado los recursos SentiWordNet [2] y WordNet Affect [3], los cuales están basados en WordNet y permiten determinar si un término en un contexto determinado expresa algún tipo de sentimiento. El primer paso sería desambiguar el término, así de esta forma se conoce el verdadero significado

del término en cuestión y finalmente determinar si tiene o no orientación sentimental.

Se debe resaltar que la idea del filtro aplicado para detectar los términos que expresan sentimientos, es totalmente novedosa, ya que permite separar los términos con información relevante para la detección de tópicos, de aquellos términos vinculados con algún tipo de sentimiento.

*SentiWordNet* : Es un recurso léxico creado especialmente para tareas relacionadas con la clasificación de sentimientos, así como en aplicaciones basadas en la minería de opinión [2]. Constituye una versión mejorada de SentiWordNet 1.0 [23] y se encuentra disponible públicamente para propósitos de investigación. SentiWordNet es el resultado de asignar a todos los sentidos de WordNet tres valores numéricos que indican el valor de polaridad (positivo, negativo y neutro), y dichos valores están en el rango [0,1] [2].

En nuestro caso, una vez desambiguado cada término, determinamos el valor positivo y negativo asignado en SentiWordNet al sentido correspondiente para cada uno de los términos analizados. En caso de que el sentido presente un valor positivo mayor que cero o un valor negativo mayor que cero, este término queda totalmente descartado y no se tiene en cuenta para el posterior análisis mediante el cual se detectan los principales tópicos abordados en los textos.

*WordNet Affect*: Es un recurso lingüístico para la representación léxica del conocimiento afectivo. Al igual que SentiWordNet, está basado en WordNet. Fue creado mediante la selección y etiquetado de sentidos de WordNet, que representan conceptos afectivos, y luego fue extendido mediante el uso de las reacciones entre términos y conceptos presentes en WordNet [3].

A diferencia de SentiWordNet, WordNet Affect no presenta la polaridad de los distintos conceptos, en su lugar etiqueta los sentidos con un conjunto de 1,903 categorías que constituyen estados afectivos. Actualmente consta de 2,874 sentidos y 4,787 términos [3]. La forma en la que ha sido utilizado es similar al anterior, cuando los términos son desambiguados, son descartados si su significado en el contexto actual ha sido etiquetado con algún estado mental en WordNet Affect.

De forma general, cuando los términos que expresan sentimientos son descartados, independientemente del recurso léxico utilizado, los términos más frecuentes que pertenecen a un tópico determinado son más afines al mismo. Además se debe señalar que son muchos los textos que tras aplicar el filtrado de sentimientos no pueden ser procesados, ya que son descartados todos sus términos. Esto se debe también en gran medida a que la gran mayoría de los textos de redes sociales solamente expresan opiniones sobre cierta temática.

### V. EXPERIMENTOS

A continuación demostraremos de forma experimental la validez de nuestra propuesta. Como se ha mencionado, no contamos con información previa de los tópicos presentes en los textos (categorías o etiquetas), por tal motivo debemos utilizar una medida no supervisada. En este caso se ha seleccionado el

Coefficiente de Silueta [24], que permite determinar la cantidad de grupos para la que el algoritmo brinda un mejor resultado.

Los conjuntos de datos para evaluar el sistema pertenecen a dos redes sociales Twitter y Dreamcatchers. Lo primera es una de las redes sociales más populares y de las más utilizadas en investigaciones relacionadas con el tema. La segunda ha sido desarrollada bajo un enfoque colaborativo entre sus miembros, y se cuenta con la base de datos que le da soporte. Los datos seleccionados de Twitter y Dreamcatchers se encuentran en inglés y español respectivamente, demostrando que la propuesta es independiente del idioma.

#### V-A. Conjuntos de datos

Se han seleccionado cuatro conjuntos de datos Tabla I, pertenecientes a Twitter y a la Red Social Dreamcatchers. Los datos de Twitter se obtuvieron del conjunto de entrenamiento de Sentiment140<sup>1</sup>, se encuentran en formato CSV y consta de seis campos, entre ellos el texto de los *tweets* el cual será utilizado en el presente trabajo. Se debe mencionar que se seleccionaron estos datos por estar orientados al Análisis de Sentimientos, y constituyen una fuente de gran importancia para la experimentación.

Por otra parte, se cuenta con la base de datos de Dreamcatchers, con un total de 61 tablas. La información recogida es toda la relacionada con los datos personales y de afiliación del usuario, así como, las interacciones que realiza en su perfil y con otros usuarios. En este caso utilizaremos los *Comentarios* de los usuarios.

Se debe mencionar que además del idioma, los textos de Twitter difieren con los de Dreamcatchers en los siguientes aspectos:

- Los textos de Dreamcatchers aunque abordan diversos tópicos, principalmente constituyen temas relacionados con el ámbito universitario, ya que los usuarios de dicha red social son estudiantes de la Universidad de Camagüey.
- La longitud de los textos de Twitter que hemos utilizado está restringida a 140 caracteres, mientras los textos de Dreamcatchers no presentan ninguna restricción.

#### V-B. Evaluación

En esta sección, se explica el procedimiento para evaluar el funcionamiento de la metodología para la detección automática de tópicos aplicando el filtro para eliminar los términos que expresan sentimientos con los distintos recursos y sin aplicarlo.

Para ello se ha utilizado como medida el Coeficiente de Silueta [24] 1. Esta medida permite analizar la calidad de los grupos creados por los algoritmos de agrupamiento jerárquico. Los valores de este coeficiente están en el intervalo de [-1;1], siendo 1 el valor ideal que deben alcanzar los distintos algoritmos de agrupamiento jerárquico.

$$S(i) = \frac{a(i) - b(i)}{\max\{a(i), b(i)\}} \quad (1)$$

<sup>1</sup><http://www.sentiment140.com/>

La experimentación se ha llevado a cabo utilizando el método Complete Link y realizando cortes para las siguientes cantidades de grupos (17, 25, 40, 60, 80, 100 y 120), y para cada caso se ha determinado el valor del Coeficiente de Silueta cuando no se aplica el filtro para eliminar los sentimientos, así como cuando es aplicado haciendo uso de los distintos recursos. En todos los casos se ha utilizado como medida de similitud la distancia del coseno.

#### V-C. Resultados y discusión

En las Tablas II-V se muestran los valores del Coeficiente de Silueta de cada conjunto experimental y las distintas cantidades de grupos, tanto cuando no se aplica el filtro para eliminar los términos que expresan sentimientos (**NF**) y cuando es aplicado utilizando SentiWordNet (**SWN**), WordNet Affect (**WA**) and la combinación de ambos (**SWN-WA**). Se puede observar a simple vista que cuando se aplica el filtrado de sentimientos, se obtienen mejores resultados que cuando no es aplicado (valores en negrita).

Con el fin de realizar un análisis más detallado de los resultados, se ha realizado un análisis estadístico para así poder determinar si existen diferencias significativas entre los valores obtenidos para los distintos número de grupos, los recursos utilizados y la fuente de los datos textuales. Las Figuras 1 y 2 muestran las gráficas del Coeficiente de Silueta con respecto a la cantidad de grupos y el recurso utilizado para detectar los términos con orientación sentimental respectivamente, utilizando en ambos casos la prueba de Kruskal-Wallis [25]. A continuación se resumen las conclusiones del análisis:

- A partir de 60 grupos en adelante los valores del Coeficiente de Silueta se estabilizan, mostrando diferencias significativas con las cantidades anteriores.
- Existe una notable diferencia entre los resultados obtenidos con los recursos **SWN** y **SWN-WA**, y los obtenidos con el recurso **WA** y cuando no se aplica ningún filtro para detectar los términos con orientación sentimental, aunque no existen diferencias significativas entre **SWN** y **SWN-WA** si tenemos en cuenta que la utilización de **SWN-WA** conlleva el uso de otro recurso léxico.

Por otra parte, la Figura 3 muestra la gráfica del Coeficiente de Silueta con respecto a la red social de la cual provienen los textos. Se realizó la prueba de Wilcoxon [26] y se puede concluir que existe una gran diferencia para las redes sociales utilizadas, pues Dreamcatchers brinda los mejores resultados. Esto se debe en gran medida a que gran parte de los usuarios de esta red pertenecen a un contexto universitario, por lo que el dominio de conversación es más restringido.



Tabla I  
DESCRIPCIÓN DE LOS CONJUNTOS DE DATOS

Conjunto	Cantidad de documentos	Fuente	Idioma	Intervención	Cantidad de términos diferentes	Cantidad total de términos
Conjunto 1	5000	Twitter	Inglés	Tweet	3189	12915
Conjunto 2	10000	Twitter	Inglés	Tweet	4597	25634
Conjunto 3	5000	Dreamcatchers	Español	Comentario	1661	8851
Conjunto 4	10000	Dreamcatchers	Español	Comentario	2218	17141

Tabla II  
COEFICIENTE DE SILUETA DEL CONJUNTO 1

Recurso/ Grupos	17	25	40	60	80	100	120
NF	0.0	0.09	0.19	0.23	0.24	0.24	0.22
SWN	0.03	0.1	0.2	0.26	<b>0.28</b>	0.27	0.27
WA	0.0	0.09	0.18	0.22	0.23	0.24	0.22
SWN-WA	0.02	0.09	0.21	0.26	0.27	0.26	0.27

Tabla III  
COEFICIENTE DE SILUETA DEL CONJUNTO 2

Recurso/ Grupos	17	25	40	60	80	100	120
NF	0.04	0.09	0.14	0.21	0.22	0.23	0.22
SWN	0.06	0.09	0.15	0.25	0.26	<b>0.27</b>	0.26
WA	0.05	0.08	0.12	0.21	0.23	0.23	0.22
SWN-WA	0.06	0.08	0.15	0.24	<b>0.27</b>	<b>0.27</b>	0.25

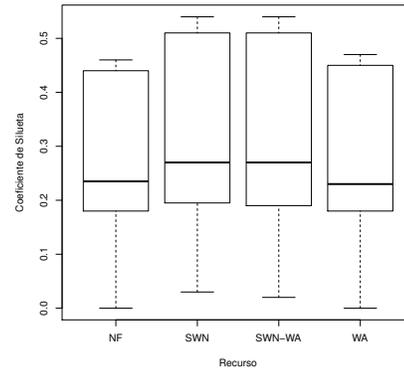


Figura 2. Gráfica entre el Coeficiente de Silueta y los recursos utilizados

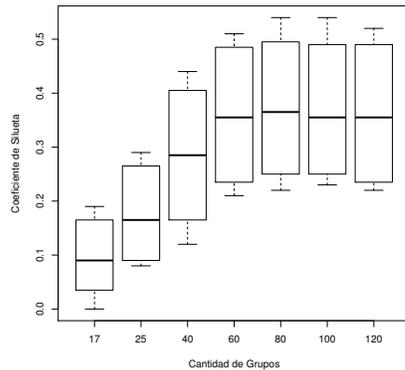


Figura 1. Gráfica entre el Coeficiente de Silueta y el número de grupos

Tabla IV  
COEFICIENTE DE SILUETA DEL CONJUNTO 3

Recurso/ Grupos	17	25	40	60	80	100	120
NF	0.13	0.24	0.37	0.45	0.45	0.44	0.44
SWN	0.19	0.29	0.44	0.51	0.52	0.52	0.52
WA	0.12	0.23	0.37	0.45	0.46	0.45	0.45
SWN-WA	0.16	0.27	0.44	0.51	<b>0.53</b>	0.51	0.52

Tabla V  
COEFICIENTE DE SILUETA DEL CONJUNTO 4

Recurso/ Grupos	17	25	40	60	80	100	120
NF	0.17	0.24	0.36	0.45	0.46	0.45	0.45
SWN	0.15	0.28	0.43	0.51	<b>0.54</b>	<b>0.54</b>	0.52
WA	0.18	0.26	0.38	0.46	0.47	0.47	0.46
SWN-WA	0.17	0.28	0.44	0.51	<b>0.54</b>	0.53	0.52

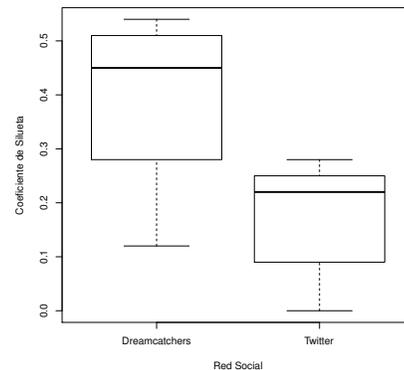


Figura 3. Gráfica entre el Coeficiente de Silueta y las redes sociales utilizadas

## VI. CONCLUSIONES Y TRABAJOS FUTUROS

En este artículo se presenta una nueva propuesta para la detección automática de tópicos en textos de redes sociales. Para ello se ha incorporado un filtro durante el preprocesamiento semántico de los textos, permitiendo detectar y eliminar los términos que presenten una orientación sentimental, ya que estos no constituyen información relevante para la detección de tópicos. Con este fin, fueron utilizados los recursos SentiWordNet y WordNet Affect por separado y combinándolos.

Los experimentos realizados tanto con Twitter como con Dreamcatchers, permiten mostrar la viabilidad del sistema. Se ha experimentado sin aplicar el filtro para eliminar los sentimientos y aplicándolo con dos recursos léxicos relacionados

con el análisis de sentimientos. En cada caso se realizaron cortes en las cantidades de grupos ya mencionadas y se calculó el Coeficiente de Silueta. Los resultados alcanzados cuando se aplicó el filtro mejoran los resultados obtenidos cuando no se aplica el filtro. El recurso con el que se obtuvo un mejor rendimiento fue SentiWordNet, pues aunque la combinación de ambos recursos mejora a SentiWordNet en determinados casos, las diferencias no son significativas teniendo en cuenta que se incorporan todos los conceptos de WordNet Affect.

El uso de algoritmos de agrupamiento jerárquico, brinda la posibilidad de agrupar los documentos en tópicos o temas y crear una jerarquía de tópicos, la cual puede ser utilizada como jerarquía de una dimensión en un modelo multidimensional y de esta forma facilitar el análisis de los datos de las redes sociales. La metodología propuesta puede ser aplicada a distintas redes sociales independientemente del idioma y de los temas tratados en dichas redes, gracias a la base de conocimiento utilizada (MCR). Se debe mencionar que MCR está basado en el recurso WordNet, integra recursos como WordNet Domains, Base Concepts, Top Ontology y la ontología AdimenSUMO y además mediante un índice (Inter-Lingual-Index ILI) integra wordnets de seis idiomas diferentes: Inglés, Español, Catalán, Euskera, Gallego y Portugués [21].

Como se mencionó anteriormente el tema tratado en la presente investigación deja abierta la posibilidad para realizar extensiones tales como incluir la jerarquía de tópicos obtenida como una nueva dimensión en un modelo multidimensional, permitiendo un mejor análisis de los datos principalmente en redes sociales, y luego de tener creados los tópicos estudiar el proceso relacionado con la de detección automática de tópicos para un nuevo texto.

#### REFERENCIAS

- [1] K. Gutiérrez-Batista, J. R. Campaña, M.-A. Vila, y M. J. Martín-Bautista, "An ontology-based framework for automatic topic detection in multilingual environments," *International Journal of Intelligent Systems*, vol. 33, no. 7, pp. 1459–1475, 2018. [Online]. Disponible: <https://onlinelibrary.wiley.com/doi/abs/10.1002/int.21986>
- [2] S. Baccianella, A. Esuli, y F. Sebastiani, "Sentiwordnet 3.0: An enhanced lexical resource for sentiment analysis and opinion mining." in *LREC*, vol. 10, 2010, pp. 2200–2204.
- [3] R. Valitutti, "Wordnet-affect: an affective extension of wordnet," in *Proceedings of the 4th International Conference on Language Resources and Evaluation*, 2004, pp. 1083–1086.
- [4] L. Chung-Hong, "Unsupervised and supervised learning to evaluate event relatedness based on content mining from social-media streams," *Expert Systems with Applications*, vol. 39, no. 18, pp. 13 338 – 13 356, 2012.
- [5] A. G. Skarmeta, A. Bensaid, y N. Tazi, "Data mining for text categorization with semi-supervised agglomerative hierarchical clustering," *International Journal of Intelligent Systems*, vol. 15, no. 7, pp. 633–646, 2000. [Online]. Disponible: [http://dx.doi.org/10.1002/\(SICI\)1098-111X\(200007\)15:7<633::AID-INT4>3.0.CO;2-8](http://dx.doi.org/10.1002/(SICI)1098-111X(200007)15:7<633::AID-INT4>3.0.CO;2-8)
- [6] L. Zheng y T. Li, "Semi-supervised hierarchical clustering," in *Proceedings of the 2011 IEEE 11th International Conference on Data Mining*, ser. ICDM '11. Washington, DC, USA: IEEE Computer Society, 2011, pp. 982–991. [Online]. Disponible: <http://dx.doi.org/10.1109/ICDM.2011.130>
- [7] B. Magnini y G. Cavaglia, "Integrating subject field codes into wordnet," in *LREC*. European Language Resources Association, 2000.
- [8] C. Lin y Y. He, "Joint sentiment/topic model for sentiment analysis," in *18th ACM Conference on Information and Knowledge Management (CIKM09)*. New York, NY, USA: ACM, 2009, pp. 375–384.
- [9] J. Duan y J. Zeng, "Web objectionable text content detection using topic modeling technique," *Expert Systems with Applications*, vol. 40, pp. 6094–6104., 2013.
- [10] J. Martínez-Romo y L. Araujo, "Detecting malicious tweets in trending topics using a statistical analysis of language," *Expert Systems with Applications*, vol. 40, pp. 2992–3000, 2013.
- [11] M. Pennacchiotti y S. Gurumurthy, "Investigating topic models for social media user recommendation," in *20th International Conference Companion on World Wide Web*. New York, NY, USA: ACM, 2011, pp. 101–102.
- [12] J. Wu, W. Gao, B. Zhang, J. Liu, y C. Li, "Cluster based detection and analysis of internet topics," in *4th International Symposium on Computational Intelligence and Design, ISCID 2011*, vol. 2, 2011, pp. 371–374.
- [13] W. X. Zhao, J. Weng, J. He, E.-P. Lim, y H. Yan, "Comparing twitter and traditional media using topic models," in *33rd European conference on advances in information retrieval (ECIR11)*. Berlin, Heidelberg: Springer-Verlag., 2011, pp. 338–349.
- [14] C. Lin, Y. He, R. Everson, y S. Ruger, "Weakly supervised joint sentiment-topic detection from text," *Knowledge and Data Engineering, IEEE Transactions on*, vol. 24, no. 6, pp. 1134–1145, June 2012.
- [15] J. Sowmiya y S. Chandrakala, "Joint sentiment/topic extraction from text," 2015, pp. 611–615, cited By 0.
- [16] Y. Rao, Q. Li, X. Mao, y L. Wenyin, "Sentiment topic models for social emotion mining," *Information Sciences*, vol. 266, pp. 90 – 100, 2014. [Online]. Disponible: <http://www.sciencedirect.com/science/article/pii/S002002551400019X>
- [17] K. Cai, S. Spangler, Y. Chen, y L. Zhang, "Leveraging sentiment analysis for topic detection," in *Web Intelligence and Intelligent Agent Technology, 2008. WI-IAT '08. IEEE/WIC/ACM International Conference on*, vol. 1, Dec 2008, pp. 265–271.
- [18] X. Ding, L. Zhang, Y. Tian, X. Gong, y W. Wang, "Dynamic topic detection model by fusing sentiment polarity," vol. 159, 2015, pp. 65–71, cited By 0.
- [19] K. Toutanova, D. Klein, C. D. Manning, y Y. Singer, "Feature-rich part-of-speech tagging with a cyclic dependency network," in *Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology - Volume 1*, ser. NAACL '03. Stroudsburg, PA, USA: Association for Computational Linguistics, 2003, pp. 173–180. [Online]. Disponible: <http://dx.doi.org/10.3115/1073445.1073478>
- [20] J. R. Finkel, T. Grenager, y C. Manning, "Incorporating non-local information into information extraction systems by gibbs sampling," in *Proceedings of the 43rd Annual Meeting on Association for Computational Linguistics*, ser. ACL '05. Stroudsburg, PA, USA: Association for Computational Linguistics, 2005, pp. 363–370. [Online]. Disponible: <http://dx.doi.org/10.3115/1219840.1219885>
- [21] A. Gonzalez-Agíre, E. Laparra, y G. Laparra, "Multilingual central repository version 3.0," in *Proceedings of the Eight International Conference on Language Resources and Evaluation (LREC'12)*. Istanbul, Turkey: European Language Resources Association (ELRA), may 2012.
- [22] C. D. Manning, P. Raghavan, y H. Schütze, *Introduction to Information Retrieval*. New York, NY, USA: Cambridge University Press, 2008.
- [23] A. Esuli y F. Sebastiani, "Sentiwordnet: A publicly available lexical resource for opinion mining," in *In Proceedings of the 5th Conference on Language Resources and Evaluation (LREC06)*, 2006, pp. 417–422.
- [24] P. Rousseeuw, "Silhouettes: A graphical aid to the interpretation and validation of cluster analysis," *J. Comput. Appl. Math.*, vol. 20, no. 1, pp. 53–65, Nov. 1987. [Online]. Disponible: [http://dx.doi.org/10.1016/0377-0427\(87\)90125-7](http://dx.doi.org/10.1016/0377-0427(87)90125-7)
- [25] W. Kruskal y W. Wallis, "Use of ranks in one-criterion variance analysis," *Journal of the American Statistical Association*, pp. 583–621, 1952.
- [26] F. Wilcoxon, "Individual comparisons by ranking methods," *Biometrics Bulletin*, vol. 1, no. 6, pp. 80–83, 1945.



# Un Algoritmo Memético, con búsqueda local basada en Label Propagation, para detectar comunidades en redes dinámicas

1<sup>st</sup> Ángel Panizo

*Departamento de ciencias de la computación  
Universidad Autónoma de Madrid  
Madrid, España  
angel.panizo@uam.es*

2<sup>nd</sup> Gema Bello-Orgaz

*Departamento de ciencias de la computación  
Universidad Autónoma de Madrid  
Madrid, España  
gema.bello@uam.es*

3<sup>rd</sup> Alfonso Ortega

*Departamento de ciencias de la computación  
Universidad Autónoma de Madrid  
Madrid, España  
alfonso.ortega@uam.es*

4<sup>th</sup> David Camacho

*Departamento de ciencias de la computación  
Universidad Autónoma de Madrid  
Madrid, España  
david.camacho@uam.es*

**Abstract**—El análisis y la detección de comunidades en redes complejas es actualmente un área de estudio en auge, ya que muchos sistemas se pueden representar como redes de nodos interconectados. Tradicionalmente el esfuerzo se ha aplicado en estudiar métodos para analizar redes estáticas, es decir, redes que no cambian en el tiempo. En el mundo real, a menudo, las redes son dinámicas, es decir, evolucionan según pasa el tiempo, debido a este fenómeno la comunidad científica se ha comenzado a interesar por el análisis de este tipo de redes. En la literatura ya se han usado con éxito tanto algoritmos genéticos como otros algoritmos bio-inspirados para detectar comunidades en redes dinámicas, pero pocos artículos se han centrado en buscar mecanismos para mejorar estos métodos explotando la temporalidad de estas redes. En este artículo presentamos un Algoritmo Memético, con búsqueda local basada en *Label Propagation*, para identificar comunidades en redes dinámicas.

**Index Terms**—detección dinámica de comunidades, algoritmos genéticos, análisis de redes complejas, algoritmos meméticos

## I. INTRODUCCIÓN

El análisis y la detección de comunidades en redes complejas es actualmente un área de estudio en auge, ya que muchos sistemas complejos se pueden representar como redes de nodos interconectados. Esta idea se ha aplicado de forma satisfactoria a una gran cantidad áreas de estudio: como el marketing [1], la salud pública [2], el cibercrimen [3]–[5] o el análisis de redes sociales [6]–[8]. La detección de comunidades es un problema *mal definido*, ya que existen varias definiciones de qué es una comunidad y no se ha llegado a un consenso entre la comunidad científica para decidir cuál de ellas es la correcta. Nosotros definiremos una comunidad

Este trabajo ha sido cofinanciado por los siguientes proyectos de investigación: EphemCH (TIN2014-56494-C4-4-P) y DeepBio (TIN2017-85727-C4-3-P). Ministerio de Economía y Competitividad de España, bajo los fondos Europeos de desarrollo regional (FEDER).

como un conjunto de nodos que interactúan más entre ellos que entre el resto de nodos de la red. Además, podemos definir dos tipos de comunidades, *solapadas* y *no-solapadas*, dependiendo del número de comunidades a las que un nodo puede pertenecer a la vez. Si un nodo puede pertenecer a varias comunidades a la vez, entonces estaremos hablando de comunidades *solapadas*. Mientras que si un nodo sólo puede pertenecer a una única comunidad, entonces hablaremos de comunidades *no-solapadas*.

Tradicionalmente el esfuerzo se ha aplicado en estudiar métodos para analizar redes estáticas, es decir, redes que no cambian en el tiempo. En el mundo real, a menudo, las redes son dinámicas, es decir, evolucionan según pasa el tiempo. Debido a este fenómeno la comunidad científica se ha comenzado a interesar por el análisis de este tipo de redes. Una red dinámica se puede modelar usando una secuencia de instancias, dónde cada instancia representa el estado de la red en un momento concreto. Las comunidades de una red dinámica son conocidas como *comunidades dinámicas*. Detectar comunidades dinámicas tiene una dificultad añadida si lo comparamos con sus homologas estáticas. No sólo es necesario agrupar cada instancia de la red en comunidades, sino que también hay que rastrear estas comunidades a lo largo de las diferentes instancias de la red.

Los métodos de detección de comunidades dinámicas se pueden dividir en dos grupos. El primer grupo incluye a aquellos métodos que hacen el paso de agrupación y el paso de rastreo de manera independiente, por ejemplo, primero se agrupa cada instancia de la red en comunidades y después se analizan los cambios que ha sufrido estas comunidades a lo largo de las distintas instancias. El segundo grupo, incluye los métodos que siguen la filosofía del *evolutionary clustering* [9], que consiste en agrupar cada instancia de la

red de tal manera que las comunidades encontradas en una instancia se parezcan, en la mayor medida de lo posible, a las comunidades encontradas en la instancia anterior. Esta filosofía asume que no se dan cambios abruptos en la red en un periodo corto de tiempo. Por motivos de claridad, a partir de ahora, a los métodos del primer grupo los llamaremos *métodos temporalmente suaves* y a los métodos del segundo grupo *métodos temporalmente no-suaves*.

Los Algoritmos Genéticos (GAs) son una meta-heurística inspirada en los principios de la selección natural de Charles Darwin y en la genética mendeliana. Los GAs son un método efectivo de resolver problemas de optimización combinatoria y se han usado anteriormente para detectar comunidades tanto estáticas [10], [11] como dinámicas [12]. También se han usado Algoritmos Meméticos para detectar comunidades estáticas. Un Algoritmo Memético es un Algoritmo genético que se ha emparejado con un método de *búsqueda local*. Los métodos de *búsqueda local* se han aplicado principalmente durante la creación de la población inicial [13] o durante el proceso de mutación [14]. En este artículo presentamos un Algoritmo Memético que usa un proceso de *búsqueda local* basado en *Label Propagation* [15] para detectar comunidades dinámicas, *no solapadas* y siguiendo un *método temporalmente no-suave*. En el método de *Label Propagation* cada nodo, de manera iterativa, cambia su comunidad para pertenecer a la misma comunidad que la mayoría de sus vecinos. El algoritmo termina cuando en una iteración ningún nodo ha cambiado su comunidad. La idea principal de nuestro algoritmo es utilizar las comunidades detectadas en una instancia de la red para guiar la búsqueda de la instancia siguiente. Nuestro método ejecuta un GAs para cada instancia de la red dinámica. La población de cada GAs se construye utilizando la población obtenida como solución para la instancia anterior. Debido a los cambios en la red, es posible que algunos de los individuos dejen de ser soluciones válidas cuando se pasan de una instancia a otra. Para solucionar este problema proponemos usar una búsqueda local basada en *Label Propagation* para *reparar* estos individuos intentando mantener la mayor cantidad de información posible. Este trabajo se centra en la agrupación de las diferentes instancias de tiempo en comunidades, dejando el posterior rastreo fuera del ámbito de este.

La principal contribución de este trabajo es la presentación y el análisis de la viabilidad de un método de búsqueda local para mejorar la eficiencia de un GAs capaz de detectar comunidades dinámicas.

El resto del artículo está organizado de la siguiente manera: en la sección II se describe la detección dinámica de comunidades de una manera formal y se presenta el Algoritmo Memético propuesto. En la sección III se presentan los procedimientos seguidos para comprobar la viabilidad y la eficiencia del método usando un *dataset* real. Por último, se muestran las conclusiones obtenidas y se proponen futuras líneas de investigación.

## II. ALGORITMO

### A. Formulación del problema

Sea  $\aleph = \{G^0..G^n\}$  una red dinámica con  $n$  instancias ordenadas en orden cronológico. Sea  $G^t$  una instancia de dicha red modelada como un grafo  $G^t(V^t, E^t)$ . Sea  $V^t$  el conjunto de vértices o nodos presentes en el instante  $t$ . Sea  $E^t$  un conjunto de conexiones, llamadas aristas, que conectan dos elementos de  $V^t$  en un instante concreto de tiempo  $t$ . Nuestro objetivo es agrupar los vértices de cada instancia de la red dinámica  $G^t$  de tal manera que los vértices que pertenezcan a un mismo grupo tengan más conexiones entre ellos que con el resto de vértices de  $G^t$  y además cada vértice pertenezca a un único grupo en cada instancia de tiempo.

### B. Algoritmo Memético

El pseudocódigo del Algoritmo Memético propuesto está disponible en el *Algoritmo 1*. Usamos un Algoritmo Genético con elitismo para detectar las comunidades en cada instancia,  $G^t$ , de la red dinámica  $\aleph$  (líneas 1-13). Para la primera instancia de la red,  $G^0$ , el método evoluciona una población generada aleatoriamente. Sin embargo, para el resto de las instancias,  $G^t | t > 0$ , en vez de evolucionar una población aleatoria, se evoluciona una población generada a partir de la población obtenida como solución para la instancia anterior. Una vez procesadas todas las instancias  $G^t$  el resultado devuelto por el algoritmo ( $C_{dinamica}$ ) es la solución codificada por el mejor individuo de cada una de las poblaciones evolucionadas (línea 13).

Cada individuo de una población codifica una posible agrupación de nodos en comunidades para una instancia  $G^t$  de la red. Los individuos codifican las soluciones usando la codificación *locus-based adjacency* propuesta en [16]. Tal como comentamos en el párrafo anterior, para la primera instancia de la red,  $G^0$ , generamos una población aleatoria (línea 7). Para generar cada individuo de la población aleatoria rellenamos cada uno de sus genes con un vecino aleatorio del nodo que codifica dicho gen. Por el contrario, para el resto de instancias de la red ( $\{G^t | t > 0\}$ ), los individuos de la población inicial se generan aplicando la función *labelBL* a cada uno de los individuos devueltos por el Algoritmo Genético ejecutado para la instancia anterior (líneas 9-11). La función *labelBL* es la función de búsqueda local basada en *Label Propagation* que *traspasa* la información de un individuo de una generación a otra. Se encarga de cambiar los genes de un individuo que remiten a nodos que han dejado de ser vecinos de el nodo que el gen codifica (líneas 16-23). Para seleccionar un nuevo valor para cada uno de estos genes: primero buscamos todos los vecinos del nodo, que codifica el gen afectado, en la instancia actual  $G^t$  (línea 18). A continuación, utilizamos la mejor solución ( $C_{last}$ ) de la instancia anterior  $G^{t-1}$  para encontrar la comunidad a la que pertenecen el mayor número de vecinos (línea 20). Por último, el valor del gen se cambia por un vecino aleatorio que pertenezca a la comunidad seleccionada en el paso anterior (línea 22).



Una vez generada la población inicial, se evoluciona siguiendo un Algoritmo Genético Elistista (línea 12) con las siguientes funciones: *Two Points Crossover*, *Tournament Selection* y *Modularity* [17] como *función de Fitness*. Además, como mutación se ha implementado una función que selecciona una serie de genes al azar y cambia sus valores por vecinos aleatorios del nodo que codifica el gen afectado. Estas funciones se seleccionaron después de revisar los operadores más utilizados en la literatura.

**Algorithm 1** Algoritmo Memético para detectar comunidades dinámicas

```

1: function ALGORITMOMEMETICO( $\mathbb{N}$ )
2:    $Conf \leftarrow ELITISM, CRXRATE$ 
3:    $Conf \leftarrow Conf \cup MUTR, MAXGEN, NCONV$ 
4:    $C_{dinamica} \leftarrow \emptyset$ 
5:    $P_{ant} \leftarrow null$ 
6:    $C_{ant} \leftarrow null$ 
7:   for all  $G^t \in \mathbb{N}$  do
8:     if  $t = 0$  then
9:        $P_{ini} \leftarrow poblacionAleatoria(G^t, POPSIZE)$ 
10:    else
11:       $P_{ini} \leftarrow \emptyset$ 
12:      for all  $ind \in P_{ant}$  do
13:         $P_{ini} \leftarrow P_{ini} \cup labelBL(ind, G^t, C_{ant})$ 
14:       $P_{ant} \leftarrow elitistaGA(P_{ini}, G^t, Conf)$ 
15:       $C_{ant} \leftarrow mejorSolucion(P_{ant})$ 
16:       $C_{dinamica} \leftarrow C_{dinamica} \cup C_{ant}$ 
17:    return  $C_{dinamica}$ 
18: function LABELBL( $ind, G^t, C_{ant}$ )
19:   for all  $i \in [1, size(ind)]$  do
20:      $vecinos \leftarrow getVecinos(i, G^t)$ 
21:     if  $ind[i] \notin vecinos$  then
22:        $com \leftarrow getComunidadComun(vecinos, C_{ant})$ 
23:        $vecinosOk \leftarrow nodosEnCom(vecinos, com)$ 
24:        $ind[i] \leftarrow seleccionAzar(vecinosOk)$ 
25:   return  $individuo$ 

```

### III. EXPERIMENTACIÓN

#### A. Descripción del dataset

En esta sección estudiaremos la efectividad del algoritmo propuesto probándolo contra el *dataset* de *Enron* [18]. Este dataset consta de los correos enviados por los empleados de la corporación Enron entre los años de 1999 y 2003. Cada vértice en el dataset representa a un trabajador de Enron y una arista uniendo dos nodos significa que esos dos empleados mantuvieron una comunicación por e-mail. Cada arista tiene asociada la fecha de cuando se produjo dicha comunicación. Usando estas fechas se ha creado una red dinámica compuesta por ocho instancias. Cada instancia tiene los correos enviados entre empleados de Enron durante quince días, los fines de semana se han excluido debido a la poca actividad que ocurre en ellos. Se han seleccionado quince días como la resolución de cada instancia de la red porque una resolución menor daba

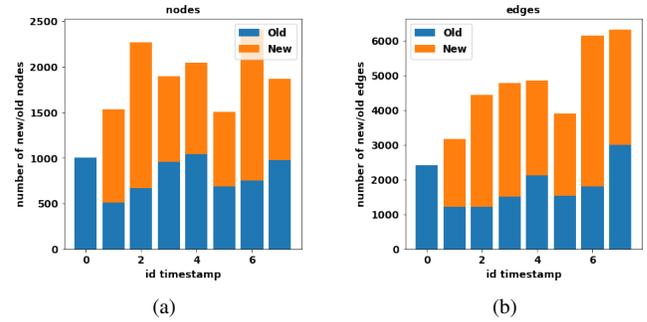


Fig. 1: Número de vértices y aristas en cada instancia. La parte azul de la barra muestra el número de elementos que estaban presentes en la instancia anterior además de en la actual. La parte naranja muestra el número de elementos que están presentes en la estancia actual pero no en la anterior.

TABLE I: Parámetros utilizados en los Algoritmos Genético y Memético

Parámetro	Descripción	Valor
<i>POPSIZE</i>	Tamaño de la población	300
<i>ELITISM</i>	Número de individuos que forman la élite	10%
<i>MAXGEN</i>	Número de máximo de generaciones	500
<i>NCONV</i>	Número de generaciones con el mismo <i>fitness</i> (+/-0.01)	10
<i>CRXRATE</i>	Probabilidad de cruce	1.0
<i>MUTR</i>	Probabilidad de Mutación	0.1

lugar a redes demasiado dinámicas para ser analizadas usando este método. Las ocho instancias que se han seleccionado son consecutivas y empiezan el 1 de Enero del 2000 y terminan el 30 de Abril del mismo año. En la figura 1 se muestran el número de nodos y aristas de cada instancia.

#### B. Resultados Experimentales

Para poder validar nuestra propuesta vamos a comparar nuestro Algoritmo Memético contra un Algoritmo Genético que no usa búsqueda local (para cada instancia de la red evoluciona una población aleatoria). Para evaluar ambos algoritmos compararemos el *fitness* del mejor individuo de cada generación obtenidos por los dos métodos. De esta manera no sólo podremos comparar cuál de los dos algoritmos obtiene un resultado mejor, sino que también podremos valorar cuál de ello lo obtiene en menos generaciones. Tanto el Algoritmo Memético como el Genético usan la misma configuración que se encuentra disponible en la Tabla I. Los diferentes parámetros se han calibrado de manera manual siguiendo un paradigma de ensayo y error.

Cada experimento se ha ejecutado 30 veces, la mediana de todas las ejecuciones está disponible en las Figuras 2 y 3. Analizando los resultados podemos concluir que nuestro Algoritmo Memético consigue mejores resultados en todas las instancias de la red a excepción de la *instancia 3* (Figura 3a). La primera instancia, la cero (Figura 2a), es un caso especial dado que al no existir una solución previa no se puede

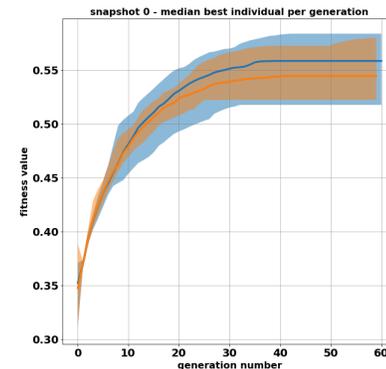
llevar a cabo la búsqueda local y se comporta igual que el Algoritmo Genético, obteniendo ambos resultados similares. Para el resto de instancias, a excepción de la tres, la población obtenida por el Algoritmo Memético es mejor que la población obtenida por el Genético durante toda la ejecución. En la *instancia 3* la población generada por el Mémetico comienza siendo mejor que la población del Genético, pero en la generación 15 este le sobrepasa y se mantiene así hasta el final. En nuestra opinión aquí yace el principal problema de este método: aunque las poblaciones del Memético siempre empiezan siendo mejores que la del genético, la velocidad de convergencia de las primeras son menores que la velocidad de las segundas. Esto se debe a que el método de búsqueda local, usado por el Algoritmo Memético, genera poblaciones con una diversidad menor que el método aleatorio, usado por el Genético, reduciendo las capacidades exploratorias del primero. Este efecto hace que el Algoritmo Memético sea más propenso a quedarse atascado en un mínimo local, justo lo que está pasando en la *instancia 3*.

#### IV. CONCLUSIONES

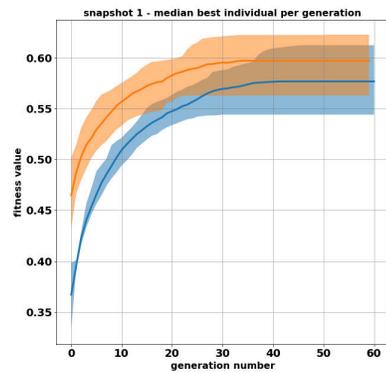
En este artículo hemos presentado un nuevo Algoritmo Memético para detectar comunidades en redes dinámicas. El método ejecuta un Algoritmo Genético elitista para cada una de las instancias que conforman la red dinámica. Entre cada ejecución del Algoritmo Genético se aplica un operador de búsqueda local basado en *Label propagation* que aprovecha la solución anterior para guiar la ejecución actual y obtener mejores resultados. Para probar la validez del método se ha comparado nuestro algoritmo contra un Algoritmo Genético sin búsqueda local usando el *dataset* de Enron. Los experimentos que se han llevado a cabo muestran que el Algoritmo Memético encuentra soluciones de más calidad que el Genético, sin embargo, también muestran que el Algoritmo Memético tiene menos capacidad exploratoria que el Genético y tiene más posibilidades de quedar estancado en un mínimo local, aunque en la mayoría de los casos estudiados esto no ocurrió. Por esta razón, nuestras futuras líneas de investigación se centrarán en estudiar otros métodos de búsqueda local o combinaciones de estos que generen poblaciones que sean a su vez diversas y de calidad. Además, también compararemos nuestro método con otros métodos del estado del arte y otros *dataset*, tanto sintéticos como reales, para determinar con más certeza si el método propuesto es o no prometedor.

#### REFERENCES

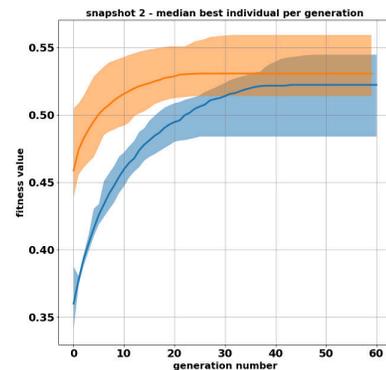
- [1] G. Bello-Orgaz, H. Menéndez, S. Okazaki, and D. Camacho, "Combining social-based data mining techniques to extract collective trends from twitter," *Malaysian Journal of Computer Science*, vol. 27, no. 2, 2014.
- [2] G. Bello-Orgaz, J. Hernandez-Castro, and D. Camacho, "Detecting discussion communities on vaccination in twitter," *Future Generation Computer Systems*, vol. 66, pp. 125–136, 2016.
- [3] R. Lara-Cabrera, A. Gonzalez-Pardo, M. Barhamgi, and D. Camacho, "Extracting radicalisation behavioural patterns from social network data," in *2017 28th International Workshop on Database and Expert Systems Applications (DEXA)*, Aug 2017, pp. 6–10.
- [4] R. Lara-Cabrera, A. Gonzalez-Pardo, and D. Camacho, "Statistical analysis of risk assessment factors and metrics to evaluate radicalisation in twitter," *Future Generation Computer Systems*, 2017.



(a)

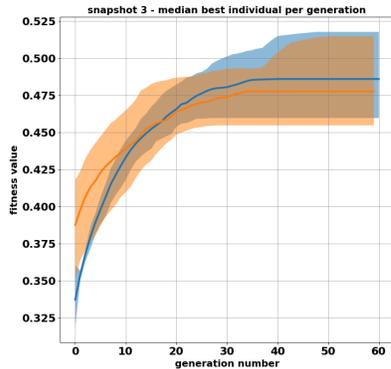


(b)

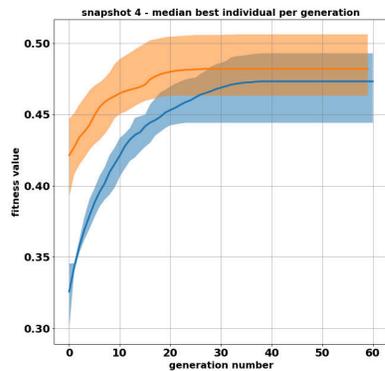


(c)

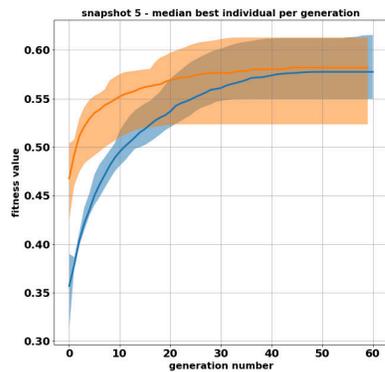
Fig. 2: Cada gráfico corresponde con una instancia de la red. En el eje X se muestra el número de generación. En eje Y el valor de la modularidad de el mejor individuo de la población. La curva naranja muestra la evolución de las poblaciones generadas pos el Algoritmo Memético y la azul la evolución del Algoritmo Genético.



(a)

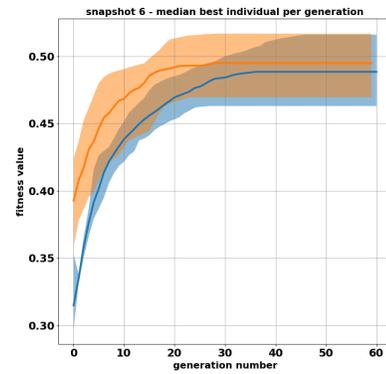


(b)

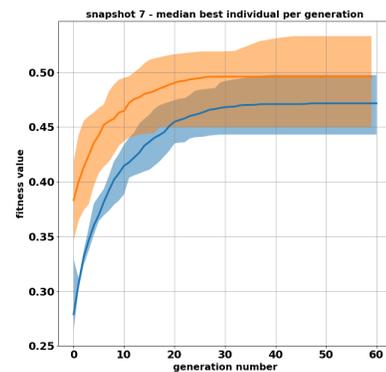


(c)

Fig. 3: Cada gráfico corresponde con una instancia de la red. En el eje X se muestra el número de generación. En eje Y el valor de la modularidad de el mejor individuo de la población. La curva naranja muestra la evolución de las poblaciones generadas pos el Algoritmo Memético y la azul la evolución del Algoritmo Genético.



(a)



(b)

Fig. 4: Cada gráfico corresponde con una instancia de la red. En el eje X se muestra el número de generación. En eje Y el valor de la modularidad de el mejor individuo de la población. La curva naranja muestra la evolución de las poblaciones generadas pos el Algoritmo Memético y la azul la evolución del Algoritmo Genético.

- [5] A. Malm and G. Bichler, "Networks of collaborating criminals: Assessing the structural vulnerability of drug markets," *Journal of Research in Crime and Delinquency*, vol. 48, no. 2, pp. 271–297, 2011.
- [6] A. Gonzalez-Pardo, J. J. Jung, and D. Camacho, "Aco-based clustering for ego network analysis," *Future Generation Computer Systems*, vol. 66, pp. 160–170, 2017.
- [7] R. Lara-Cabrera, A. G. Pardo, K. Benouaret, N. Faci, D. Benslimane, and D. Camacho, "Measuring the radicalisation risk in social networks," *IEEE Access*, vol. 5, pp. 10 892–10 900, 2017.
- [8] J. Del Ser, J. L. Lobo, E. Villar-Rodríguez, M. N. Bilbao, and C. Perfecto, "Community detection in graphs based on surprise maximization using firefly heuristics," in *Evolutionary Computation (CEC), 2016 IEEE Congress on*. IEEE, 2016, pp. 2233–2239.
- [9] D. Chakrabarti, R. Kumar, and A. Tomkins, "Evolutionary clustering," in *Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining*. ACM, 2006, pp. 554–560.
- [10] G. Bello-Orgaz, H. D. Menéndez, and D. Camacho, "Adaptive k-means algorithm for overlapped graph clustering," *International journal of neural systems*, vol. 22, no. 05, p. 1250018, 2012.
- [11] R. Francisquini, V. Rosset, and M. C. Nascimento, "Ga-lp: A genetic algorithm based on label propagation to detect communities in directed networks," *Expert Systems with Applications*, vol. 74, pp. 127–138, 2017.
- [12] F. Folino and C. Pizzuti, "An evolutionary multiobjective approach for community discovery in dynamic networks," *IEEE Transactions on Knowledge and Data Engineering*, vol. 26, no. 8, pp. 1838–1852, 2014.



- [13] S. B. Mathias, V. Rosset, and M. C. Nascimento, "Community detection by consensus genetic-based algorithm for directed networks," *Procedia Computer Science*, vol. 96, pp. 90–99, 2016.
- [14] S. Li, Y. Chen, H. Du, and M. W. Feldman, "A genetic algorithm with local search strategy for improved detection of community structure," *Complexity*, vol. 15, no. 4, pp. 53–60, 2010.
- [15] U. N. Raghavan, R. Albert, and S. Kumara, "Near linear time algorithm to detect community structures in large-scale networks," *Physical review E*, vol. 76, no. 3, p. 036106, 2007.
- [16] Y. Park and M. Song, "A genetic algorithm for clustering problems," in *Proceedings of the third annual conference on genetic programming*, vol. 1998, 1998, pp. 568–575.
- [17] M. E. Newman and M. Girvan, "Finding and evaluating community structure in networks," *Physical review E*, vol. 69, no. 2, p. 026113, 2004.
- [18] B. Klimt and Y. Yang, "Introducing the enron corpus." in *CEAS*, 2004.



# Design of an ACO algorithm for Solving Community Finding Problems

Antonio Gonzalez-Pardo  
Computer Science Department  
Universidad Autónoma de Madrid  
Email: antonio.gonzalez@uam.es

David Camacho  
Computer Science Department  
Universidad Autónoma de Madrid  
Email: david.camacho@uam.es

**Abstract**—The amount of data generated by social media users is increasing exponentially mainly produced by the high number of users connected everyday that interacts with each other through the Social Network (SN). As a result, SNs has become an interesting domain for research due to the wide variety of problems that can be solved. Among these problems, this work is focused on Community Finding Problems (CFP) whose goal is to group the different users in several clusters in such a way users belonging to the same cluster are similar (according to a specific metric) whereas they are different from the users of the other clusters. In this work, we describe the algorithm proposed in [1]. This algorithm for CFP is based on Ant Colony Optimization (ACO) algorithm, and it uses the information regarding the topology of the network, i.e. the connections of the users in the SN. For the experimental phase, we have compared the performance of the described algorithm against the performance of some well-known algorithms extracted from the State-of-the-Art. The results reveal that the proposed Topology-based ACO algorithm is a good approach to solve the community finding problem and it provides competitive results against the analyzed algorithms.

## I. INTRODUCTION

Nowadays, Social Networks (SNs) has become a powerful tool for a wide variety of purposes. The main reason lies in the number of users that connects to these SNs everyday. Initially, the goal of any SN is to put people in touch with each other and also to publish different media contents. In this sense, for example Instagram is mainly used for sharing photos, whereas Twitter is used for sharing small text messages called tweets.

Nevertheless, the number of users connected to these SNs generates such quantity of information that its analysis has attracted the attention of both, the research community and the industry. The main reason is the wide variety of applications that can be developed using these data.

In this sense, the most classical problem faced when working with Twitter is to analyze the content of the tweets and perform sentiment analysis over the tweets published by the users [2]. Other works try to identify the key players in a social network [3]. This last application domain is motivated by the usage that radical groups, as terrorist supporters, are using the SNs, such as Islamic State of Iraq and Syria (ISIS), to disseminate their propaganda. Joining both applications

appear works like [4], [5], [6] where authors try to determine the radicalization level of different users based on the content of their tweets. Finally, other works tries to determine the structure hidden by the relations of users in the SNs, like [7], what is called Community Finding Problems (CFPs).

This work provides a summary of our current results presented in [1] on the detection of communities within a given SN. Although there are several valid approaches to perform this task such as Iterated Greedy [7], or Genetic Algorithms [8], in this work the algorithm selected to perform this task has been Ant Colony Optimization (ACO) [9].

## II. THE ACO MODEL FOR CFP

This section provides a short description of the ACO model designed to find the different communities in the SN [1].

Any CFP can be modeled as a Constraint Satisfaction Problem (CSP) where the goal is to assign a cluster to each user of the SN whereas some constraints are satisfied, such as: each cluster must contain at least one user, or users belonging to the same are similar. Traditionally, solving any CSP using an ACO algorithm implies the creation of a decision graph where the ants are executed. This graph is composed by  $X \cdot k$  nodes, where  $X$  is the number of elements of the dataset and  $k$  is the number of clusters. As it can be understood, the main disadvantage of this representation is related to the size of the resulting graph. If the number of nodes increases, it could be difficult to work with the corresponding graph. And also, this representation implies the definition of the number of clusters before execution.

The model described in this paper is focused on the reduction of the resulting graph. In such a way, the resulting graph does not depend on the number of clusters, but on the number of elements in the dataset (i.e. the number of users in the SN). The task of assigning a cluster to the different users is carried out by the ants, while they are moving through the graph. In this case, the ants travel through the graph visiting the different nodes that represents the users of the dataset. The goal of each ant is to visit all the nodes, because the need to analyze all the users of the dataset. Each time, any ant arrives to a node, the ant has to decide the cluster that

will contain this user using the standard equation of the ACO algorithm.

In order to do that, the ants use a modified heuristic function  $\tau_{ij}$  that measures how good is to incorporate the user  $e_i$  to the cluster  $C_j$  by analyzing the different connections between  $e_i$  and the other users that compose the cluster  $C_j$ . This heuristic function is shown in Eq. 1.

$$\tau_{ij} = \text{Topology}(e_i, C_j) = \frac{|\mathcal{N}_i \cap C_j|}{|\mathcal{N}_i|} \quad (1)$$

Where  $\mathcal{N}_i$  represents the set of elements connected to  $e_i$  and  $|\cdot|$  is a function that compute the number of elements contained in a specific set. Therefore, this function takes into account how many connections of  $e_i$  belongs to the cluster  $C_j$ .

### III. EXPERIMENTAL EVALUATION

For testing the designed algorithm, we have used the dataset published by SNAP<sup>1</sup>. This dataset is composed by 10 different Ego Networks, and it has been selected because the dataset contains the groundtruth with the communities that compose the networks.

For the experimental phase, we have compared the performance of the ACO model against some of the well-known algorithms extracted from the State-of-the-Art. Table I shows for each algorithm how many networks each algorithm provides the best solution. Note that the best solution is the one with the highest Omega Index.

	Facebook	
	Total	Percentage
Topology-based ACO	5	50
Walktrap	1	10
Infomap	3	30
Clauset Newman Moore	1	10
Label Propagation	0	0

TABLE I

THIS TABLE SHOWS FOR EACH ALGORITHM (FIRST COLUMN), HOW MANY EGO NETWORKS EACH ALGORITHM HAS PROVIDED THE BEST SOLUTION AND THE RELATED PERCENTAGE (%) FOR EACH DATASET ANALYZED. THE BEST SOLUTION IS THE ONE THAT PROVIDES THE HIGHEST OMEGA INDEX SCORE BECAUSE IT IS THE CLOSEST TO THE GROUNDTRUTH.

### IV. CONCLUSIONS AND FUTURE WORK

This work provides a summary of the work published in [1]. In that work, we described an implementation of a new Ant Colony Optimization (ACO) algorithm to perform the community finding tasks in Social Networks (SNs), based on the topology information of the network.

In the experimental phase, we compared the performance of the described algorithm against some of the state-of-the-art

algorithms. The results reveal that the proposed Topology-based ACO algorithm is a good approach to solve the community finding problem because it provides competitive results against the analyzed algorithms.

As future work, we are working on the adaptation of novel bio-inspired algorithm to perform community finding tasks. These algorithms are Artificial Bee Colony [3] and a new algorithm based on the calling behavior of male Japanese tree frogs [10].

### ACKNOWLEDGMENT

This work has been co-funded by the following research projects: Spanish Ministry of Science and Education and Competitiveness (MINECO) and European Regional Development Fund (FEDER) under grant TIN2017-85727-C4-3-P (DeepBio); and the Justice Programme of the European Union (2014-2020) 723180 – RiskTrack – JUST-2015-JCOO-AG/JUST-2015-JCOO-AG-1. The contents of this publication are the sole responsibility of their authors and can in no way be taken to reflect the views of the European Commission.

### REFERENCES

- [1] A. Gonzalez-Pardo, J. J. Jung, and D. Camacho, "Aco-based clustering for ego network analysis," *Future Generation Computer Systems*, vol. 66, pp. 160 – 170, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0167739X16302278>
- [2] A. Giachanou and F. Crestani, "Like it or not: A survey of twitter sentiment analysis methods," *ACM Comput. Surv.*, vol. 49, no. 2, pp. 28:1–28:41, Jun. 2016. [Online]. Available: <http://doi.acm.org/10.1145/2938640>
- [3] M. Lozano, C. Garca-Martinez, F. J. Rodriguez, and H. M. Trujillo, "Optimizing network attacks by artificial bee colony," *Information Sciences*, vol. 377, pp. 30 – 50, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0020025516312075>
- [4] M. Fernandez, M. Asif, and H. Alani, "Understanding the roots of radicalisation on twitter," in *In WebSci '18: 10th ACM Conference on Web Science*. ACM (Association for Computing Machinery), May 2018. [Online]. Available: <http://oro.open.ac.uk/54344/>
- [5] R. Lara-Cabrera, A. Gonzalez-Pardo, and D. Camacho, "Statistical analysis of risk assessment factors and metrics to evaluate radicalisation in twitter," *Future Generation Computer Systems*, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0167739X17308348>
- [6] R. Lara-Cabrera, A. G. Pardo, K. Benouaret, N. Faci, D. Benslimane, and D. Camacho, "Measuring the radicalisation risk in social networks," *IEEE Access*, vol. 5, pp. 10 892 – 10 900, 2017.
- [7] J. Sánchez-Oro and A. Duarte, "Iterated greedy algorithm for performing community detection in social networks," *Future Generation Computer Systems*, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0167739X17323932>
- [8] C. Pizzuti, "Ga-net: A genetic algorithm for community detection in social networks," in *Parallel Problem Solving from Nature – PPSN X*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, pp. 1081–1090.
- [9] M. Dorigo, "Optimization, learning and natural algorithms (in Italian)," Ph.D. dissertation, Dipartimento di Elettronica, Politecnico di Milano, Milan, Italy, 1992.
- [10] C. Blum, B. Calvo, and M. J. Blesa, "Frogcol and frogmis: new decentralized algorithms for finding large independent sets in graphs," *Swarm Intelligence*, vol. 9, no. 2, pp. 205–227, Sep 2015. [Online]. Available: <https://doi.org/10.1007/s11721-015-0110-1>

<sup>1</sup><http://snap.stanford.edu/data/egonets-Facebook.html>

**I Workshop en  
Ciencia de Datos  
en Redes Sociales  
(CidReS 2018)**

SESIÓN 3







# Red Neural Recurrente para la Desambiguación de Entidades en Datos de Medios Sociales

Cristina Zuheros, Siham Tabik, Ana Valdivia, Eugenio Martínez-Cámara y Francisco Herrera  
Instituto Andaluz de Investigación en Ciencias de Datos e Inteligencia Computacional,  
Universidad de Granada, 18071 Granada, España  
Email: {czuheros, siham, avaldivia}@ugr.es, {emcamara, fherrera}@decsai.ugr.es

**Resumen**—Un reto particular en el ámbito del Procesamiento del Lenguaje Natural es la desambiguación de palabras polisémicas. La gran disponibilidad, diversidad y rapidez cambiante de los datos en línea fuerzan el desarrollo de sistemas de desambiguación con una dependencia reducida de los recursos lingüísticos. Se parte de la base que la codificación del contexto de una entidad específica no requiere del uso de recursos lingüísticos externos como bases de conocimiento, por lo que se propone una arquitectura de red neuronal basada en el uso de las Redes Neuronales Recurrentes *Long Short-Term Memory* para codificar el contexto de una entidad, concretamente el modelo *Two k-Contextual Windows*. Se considera un problema real que requiere la desambiguación de la entidad *Granada*. Se genera y proporciona un corpus etiquetado de comentarios extraídos de medios sociales escritos en inglés, los cuales se utilizan para evaluar nuestra propuesta. Los resultados demuestran la validez de nuestra hipótesis.

## I. INTRODUCCIÓN

La mayoría de las palabras tienen más de un significado posible ya que el lenguaje humano es inherentemente ambiguo. Los humanos somos capaces de identificar el sentido de una palabra analizando el contexto en el que esta aparece. Actualmente, una enorme cantidad de información, incluyendo textos, imágenes y vídeos, está disponible en distintas plataformas de Internet como son *Twitter*, *Instagram*, *Tripadvisor* y *Booking*, entre otros [1] y [2]. La gran cantidad de información que puede obtenerse de esas fuentes es muy valiosa en distintos campos. Por ejemplo, saber lo que se piensa sobre una entidad, un producto, un evento, una persona o un lugar, nos permite usar dicha información para mejorar un servicio y aumentar el número de clientes o turistas. Extraer esta información sobre una entidad con un significado específico de una enorme cantidad de datos requiere filtrar aquellas menciones que hacen referencia a otros posibles significados de la entidad en cuestión.

La desambiguación del sentido de la palabra (*Word Sense Disambiguation* - WSD) es la tarea del Procesamiento del Lenguaje Natural que se encarga de la asignación computacional del sentido o significado correcto de una palabra dependiendo de su contexto [3] y [4]. Esta tarea requiere una gran cantidad de información y conocimiento. Actualmente, se vuelve cada vez más desafiante, ya que los sentidos de las palabras son muy diversos e incluso cambiantes, especialmente en escenarios donde la vinculación de un nuevo sentido a una entidad es impredecible. Además, los sistemas supervisados de WSD dependen altamente de las características anotadas a mano, las

cuales también se ven afectadas por el problema anteriormente mencionado. Por tanto, la tarea de desambiguación se ve limitada por el cuello de botella de la adquisición de conocimiento y la naturaleza siempre cambiante del lenguaje.

El estado del arte en WSD queda determinado principalmente por modelos supervisados y actualmente por métodos de aprendizaje profundo basados en un tipo específico de redes neuronales recurrentes conocido como modelo *Long Short-Term Memory* (LSTM), como el modelo *Targeted Two k-Contextual Windows* [5]. Sin embargo, esos modelos neuronales no han sido evaluados en *corpora* obtenidos de medios sociales. Este tipo de datos presentan unas características propias como el uso informal del lenguaje y el uso de *emojis* para la expresión de emociones [6]. Estas características específicas hacen más desafiante la tarea.

Las contribuciones que se hacen en este trabajo se pueden resumir en: (1) nueva arquitectura neuronal basada en LSTM para la desambiguación de entidades, llamada *Two k-Contextual Windows*. Consideramos como caso de estudio la desambiguación de la entidad *Granada*. Y (2) nuevo corpus etiquetado manualmente cada uno de los sentidos de la entidad objeto de estudio. El corpus está compuesto por textos publicados en *Twitter* e *Instagram*.

Dicho documento está estructurado de la siguiente manera: la Sección II abarca la definición de WSD como tarea de clasificación y un breve análisis sobre los trabajos más cercanos. La descripción del modelo propuesto se muestra en la Sección III, y la generación del corpus utilizado para la evaluación se presenta en la Sección IV. El marco experimental se muestra en la Sección V, mientras que los resultados experimentales se presentan en la Sección VI. Por último, en la Sección VII se presentan las conclusiones y los trabajos futuros.

## II. CONTEXTO

En esta Sección se exponen las bases para entender nuestra propuesta. En la Sección II-A se define la tarea de clasificación de WSD junto con los *word embeddings*. En la Sección II-B se presenta la LSTM RNN y en la Sección II-C se revisan los trabajos más relacionados.

### II-A. Aprendizaje de secuencias para WSD y embeddings

WSD puede definirse como la identificación automática del sentido más adecuado de una palabra a la misma en función de su contexto. Puede verse como una tarea de clasificación.

Sea  $T$  una secuencia de  $n$  palabras  $\{w_1, \dots, w_n\}$ , la tarea de desambiguación consiste en encontrar una función  $A$  de palabras a sentidos, tal que  $A(w_j) \subseteq \text{sentido}_D(w_j)$  siendo  $\text{sentido}_D(w_j)$  el conjunto de sentidos posibles de la palabra  $(w_j)$  en un diccionario de sentidos  $D$ .

En este trabajo,  $T$  es el conjunto de comentarios extraídos de *Twitter* e *Instagram*, la palabra a desambiguar  $w_t$  es *Granada* y  $D$  es el conjunto de posibles significados que se detallan en la Sección IV-A. Se propone representar mediante vectores de *word embeddings* la secuencia de palabras  $\{w_1, \dots, w_n\}$  de cada secuencia de entrada  $T$  y codificarlas posteriormente con una LSTM RNN.

Un *embedding* es una representación de un objeto topológico en un espacio determinado, de forma que se conservan sus propiedades de conectividad o algebraicas [7] y [8]. Un vector *word embedding* es la representación del espacio semántico ideal de palabras en un espacio vectorial continuo. Matemáticamente, se define un *word embedding*  $w_j$ , como un vector  $d$ -dimensional  $\mathbf{we}_j^T = (we_1, \dots, we_d) \in \mathbb{R}^d$ . Por tanto, se define  $WE_{1:n} \in \mathbb{R}^{d \times n}$  como la matriz de *word embeddings* del conjunto de palabras  $\{w_1, \dots, w_n\}$ . Algunos de los modelos más destacados para realizar *word embeddings* son *word2vec* [9] y *GLoVe* [10].

### II-B. Red neuronal de memoria de corto y largo plazo

LSTM es un tipo de RNN con la capacidad de representar entradas secuenciales de tamaño arbitrario en un vector de tamaño fijo y prestar atención a las propiedades estructuradas de las entradas [11]. Dado que se pretende desambiguar una palabra en una entrada secuencial de tamaño arbitrario, LSTM cumple con los requisitos de nuestro problema.

A continuación, se definen las bases de RNN que también son la base de LSTM. Una RNN se define como una función  $R$  que se aplica recursivamente a una secuencia de palabras, concretamente en nuestro caso una secuencia de *word embeddings*  $(\mathbf{we}_1, \dots, \mathbf{we}_n)$ . La función  $R$  toma como entrada un vector de estado  $\mathbf{s}_{j-1}$  y un vector  $\mathbf{we}_j$ , y genera un nuevo vector estado  $\mathbf{s}_j$ . Este vector estado es proyectado en un vector salida  $\mathbf{y}_j$  mediante una función determinística  $O(\cdot)$ . La Ecuación 1 resume dicha definición.

$$\begin{aligned} RNN(WE_{1:n}; \mathbf{s}_0) &= \mathbf{y} \\ \mathbf{y}_j &= O(\mathbf{s}_j) \\ \mathbf{s}_j &= R(\mathbf{s}_{j-1}, \mathbf{we}_j) \end{aligned} \quad (1)$$

Las RNNs presentan el problema del desvanecimiento del gradiente [12] y [13], lo que significa que la multiplicación repetida de parámetros en la función  $R$  puede hacer que los valores de esos parámetros se desvanezcan o exploten, lo que hace más difícil el entrenamiento de la red neuronal. LSTM fue la primera RNN con una arquitectura diseñada para resolver dicho problema [12] y [13].

LSTM [14] separa el vector estado ( $\mathbf{s}_j$ ) en dos mitades, siendo una mitad considerada como “celdas de memoria” y la otra como memoria de trabajo. El mecanismo de LSTM decide en cada entrada de la secuencia qué cantidad de la nueva entrada ( $we_j$ ) debe escribirse en la celda de memoria

y qué cantidad del contenido de la celda de memoria debe olvidarse [15].

Desde un punto de vista lingüístico, la operación recursiva de LSTM significa que cada palabra ( $w_j$ ) está codificada con el significado de las palabras anteriores ( $R_{LSTM}(\mathbf{s}_{j-1}, \mathbf{we}_j)$ ). Sin embargo, el contexto de una palabra no sólo depende de las palabras localizadas antes de esa palabra, sino también en las palabras que se encuentran después de ella en la oración. Las LSTMs son versátiles, pueden funcionar en direcciones diferentes y sus salidas pueden combinarse de maneras diferentes. Formalmente, dado un vector de *word embeddings*  $(\mathbf{we}_1, \dots, \mathbf{we}_n)$ , y una palabra a desambiguar,  $\mathbf{we}_t$ , una LSTM puede codificar las palabras de la secuencia de entrada tanto de izquierda a derecha ( $\overrightarrow{\text{LSTM}}$ ) como de derecha a izquierda ( $\overleftarrow{\text{LSTM}}$ ), como indican las flechas. Las salidas de ambas LSTMs pueden ser combinadas y procesadas por una o más capas. Por tanto, codificar el significado de una secuencia de palabras puede ser expresado mediante una función  $G(\cdot)$  que combina la salida de un número  $m$  de redes LSTMs (ver Ecuación 2).

$$\text{meaning} = G(\text{LSTM}_{1:m}) \quad (2)$$

### II-C. Trabajos afines

Los principales enfoques que se encuentran en la amplia literatura [3] y [4] sobre WSD pueden clasificarse en cuatro grupos: (1) Métodos basados en el conocimiento, (2) no supervisados, (3) semisupervisados, y (4) supervisados. Nos centramos en la categoría supervisada.

Aunque los modelos supervisados requieren que el sentido de los datos sea manualmente etiquetado por humanos expertos, superan a los sistemas basados en conocimiento en los *benchmarks* estándar [16]. Se basan en el hecho de que palabras semánticamente similares tienden a tener distribuciones contextuales similares [17], [18] y [19]. Gran cantidad de modelos utilizan características manuales y métodos tradicionales de aprendizaje automático, como el sistema IMS [20] y [21].

Recientemente, los métodos de aprendizaje profundo están mostrando resultados muy prometedores [22], [23], [24], [25] y [26]. Melamud et al. [27] presentaron un modelo no supervisado basado en LSTM bidireccional. En el trabajo [28] utilizaron una arquitectura similar de red neuronal pero bajo un enfoque semi-supervisado para codificar el contexto de la palabra a desambiguar. En el trabajo [5] utilizaron una arquitectura similar combinada con capas ocultas bajo un enfoque supervisado, logrando una alta precisión en la tarea de desambiguación léxica de las primeras ediciones de Senseval [29] y [30].

## III. MODELO NEURONAL PARA WSD

En la Sección III-A, se detalla el modelo LSTM basado en una arquitectura similar a la utilizada en [5]. En la Sección III-B, se presenta nuestra propuesta.

Ambos modelos<sup>1</sup> se basan en la codificación de una ventana contextual, que definimos como un número fijo de  $k$  palabras

<sup>1</sup>Sentencia mostrada en las Figuras 1 y 2: “La ciudad de Granada es muy bonita en invierno.”



consecutivas de la secuencia de entrada. Además, comparten la capa de entrada y representación. La capa de entrada es definida como una secuencia de  $n$  palabras,  $\{w_1, \dots, w_n\}$ . La capa de representación es una matriz de *word embeddings*, definida como  $WE_{1:n}$ . Se usa el conjunto de pre-entrenado de vectores de *word embeddings* 6B *GloVe* [10]. Se aplica *Dropword* como método de regularización.

Los modelos difieren en: (1) la dirección en la que el modelo procesa las palabras de cada ventana contextual, y (2) la posición de la palabra en la sentencia, a partir de la cual el modelo inicia el procesamiento de cada ventana de contexto.

### III-A. Targeted Two $k$ -Contextual Windows

El modelo *Targeted Two  $k$ -Contextual Windows*, al que nos referiremos como  $CW^{t-k}CW^{t+k}$  tiene una arquitectura similar al modelo presentado en [5]. Determina las  $k$ -palabras de la ventana de contexto basándose en la posición de la palabra a desambiguar  $w_t$ . La primera ventana de contexto incluye las  $k$ -palabras situadas a la izquierda de la palabra a desambiguar mientras que la segunda ventana considera las  $k$ -palabras situadas a la derecha de  $w_t$  (ver Figura 1).

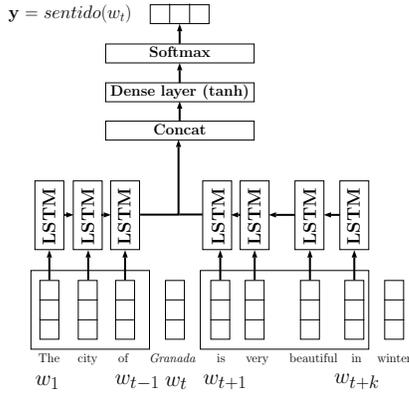


Figura 1. Modelo Targeted Two  $k$ -Contextual Windows considerando  $k = 4$ .

Las dos ventanas de contexto son procesadas por dos LSTM con  $d_{LSTM}$  unidades ocultas. El último vector de estado de las dos LSTMs son concatenadas y procesadas por una capa completamente conectada con  $h_{dense}$  unidades ocultas activadas mediante una función tangente hiperbólica ( $\tanh$ ). Finalmente, una capa *softmax* calcula la distribución de probabilidad correspondiente al conjunto de sentidos posibles de  $w_t$ . La ecuación 3 muestra las operaciones subyacentes.

$$\begin{aligned}
 \text{sentido}(w_t) &= \arg \max_{s \in S}(\mathbf{y}), \mathbf{y} \in \mathbb{R}^s \\
 \mathbf{y} &= \text{softmax}(\mathbf{c}), \mathbf{c} \in \mathbb{R}^{h_{dense}} \\
 \mathbf{c} &= \text{dense}(\mathbf{concat}), \mathbf{concat} \in \mathbb{R}^{2 \cdot h_{LSTM}} \\
 \mathbf{concat} &= [\mathbf{m}^1; \mathbf{m}^2], \mathbf{m}^1, \mathbf{m}^2 \in \mathbb{R}^{h_{LSTM}} \\
 \mathbf{m}^2 &= \underline{\text{LSTM}}(WE_{t+1:t+k}), WE_{t+1:t+k} \in \mathbb{R}^{d \times k} \\
 \mathbf{m}^1 &= \underline{\text{LSTM}}(WE_{t-k:t-1}), WE_{t-k:t-1} \in \mathbb{R}^{d \times k}
 \end{aligned} \quad (3)$$

### III-B. Two $k$ -Contextual Windows

Se propone un modelo que, a diferencia del modelo previo (ver Sección III-A), permite codificar las primeras y últimas  $k$ -palabras de la secuencia de entrada sin tener en cuenta la

posición de  $w_t$  y permite solapar las dos ventanas de contexto. El modelo *Two  $k$ -Contextual Windows* ( $CW^kCW^{n-(k-1)}$ ) procesa dos ventanas de contexto de  $k$ -palabras en direcciones opuestas. La primera analiza la oración hasta la palabra localizada en la posición  $k$  y la segunda analiza desde la palabra localizada en la posición  $n-(k-1)$ , siguiendo las direcciones indicadas por las flechas, como muestra la Figura 2.

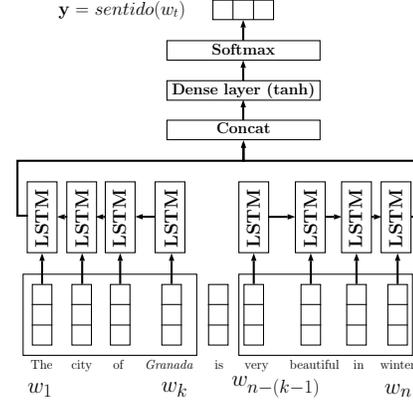


Figura 2. Modelo Two  $k$ -Contextual Windows considerando  $k = 4$ .

Ambas ventanas de contexto son individualmente procesadas usando una LSTM con  $h_{LSTM}$  unidades ocultas. Las salidas son concatenadas y procesadas por una capa completamente conectada con  $h_{dense}$  unidades ocultas activadas mediante una función tangente hiperbólica. Finalmente, *softmax* proporciona el sentido de la palabra a desambiguar  $w_t$ . La ecuación 4 muestra las operaciones realizadas por cada capa.

$$\begin{aligned}
 \text{sentido}(w_t) &= \arg \max_{s \in S}(\mathbf{y}), \mathbf{y} \in \mathbb{R}^s \\
 \mathbf{y} &= \text{softmax}(\mathbf{c}), \mathbf{c} \in \mathbb{R}^{h_{dense}} \\
 \mathbf{c} &= \tanh(\mathbf{concat}), \mathbf{concat} \in \mathbb{R}^{2 \cdot h_{LSTM}} \\
 \mathbf{concat} &= [\mathbf{m}^1; \mathbf{m}^2], \mathbf{m}^1, \mathbf{m}^2 \in \mathbb{R}^{h_{LSTM}} \\
 \mathbf{m}^2 &= \underline{\text{LSTM}}(WE_{1:k}), WE_{1:k} \in \mathbb{R}^{d \times k} \\
 \mathbf{m}^1 &= \underline{\text{LSTM}}(WE_{n-(k-1):n}), WE_{n-(k-1):n} \in \mathbb{R}^{d \times k}
 \end{aligned} \quad (4)$$

## IV. GENERACIÓN DEL CORPUS

En la siguiente Sección se describen los diferentes sentidos de la entidad *Granada* (Sección IV-A), se expone el pre-procesamiento de los datos (Sección IV-B) y la anotación del corpus (Sección IV-C).

### IV-A. Palabra a desambiguar

Un análisis profundo realizado en diferentes fuentes de Internet ha demostrado que la palabra *Granada* tiene al menos 54 sentidos. Los sentidos más frecuentes pueden agruparse en: Sentido 1: Provincia/Ciudad/Calle localizada en el sureste de España, evento (no relacionado con música o deporte) o monumento/establecimiento de dicha localización.

Sentido 2: País/Provincia/Ciudad/Distrito/Calle/Río no localizado en España.

Sentido 3: Fruto, granada.

Sentido 4: Referencias a música o deporte.

Sentido 5: Otros significados menos relevantes como usuarios de redes sociales, canales de televisión, vehículos, periódicos, entre otros.

#### IV-B. Pre-procesamiento del corpus

El conjunto de datos contiene un total de 876.969 comentarios y opiniones que incluyen la palabra *Granada* publicados por usuarios de *Twitter* e *Instagram*. Cada instancia del dataset presenta los campos siguientes:

- *uid*: identificador de la instancia.
- *source*: fuente de la instancia.
- *body*: texto, comentario de la instancia.

La mayoría de las instancias que provienen de medios sociales contienen *emojis*, ya que son útiles para expresar los sentimientos de las personas [31]. Estos sentimientos pueden sugerir si una persona está hablando sobre un tema u otro. Por ejemplo, si una usuaria usa algunos *emojis* mostrando frutas, probablemente no esté hablando sobre deporte. Como los *emojis* no pueden ser procesados directamente por los modelos, se utiliza una descripción con palabras para representar cada *emoji*. Se elabora un diccionario de *emojis* público que contiene un total de 837 *emojis* expresados en inglés<sup>2</sup>.

Se eliminan todas URLs e imágenes, dado que el procesamiento de imágenes no forma parte del flujo de trabajo de nuestra propuesta. Se eliminan los comentarios carentes de contenido y los caracteres repetitivos ya que no son útiles para nuestra tarea. Finalmente, se reemplazan caracteres como  $\langle 3, = \rangle$  por “love”/“amor”, “I am happy”/“Estoy feliz”, entre otros.

#### IV-C. Etiquetado del corpus

La primera autora, que tiene un alto dominio del inglés, etiquetó manualmente las instancias del conjunto de datos. Cada instancia se anota con un solo sentido. La Tabla I muestra el número de comentarios por cada sentido. El conjunto de instancias etiquetadas se almacena en un archivos XML.

Sentido 1	Sentido 2	Sentido 3	Sentido 4	Sentido 5	Total
11.985	3.381	452	7.438	1.445	24.701

Tabla I  
NÚMERO DE INSTANCIAS ETIQUETADAS PARA CADA SENTIDO.

### V. MARCO EXPERIMENTAL

Se realiza una experimentación profunda con el fin de evaluar nuestra propuesta. En primer lugar, se establecen dos subconjuntos de entrenamiento y test con el objetivo de evaluar nuestro modelo neuronal mediante diferentes distribuciones de los datos. También se evalúa la relevancia del uso de *emojis* como características para la tarea de desambiguación.

Además, se considera XGBoost como caso base, ya que presenta buenos resultados en tareas de clasificación. Dado que se considera WSD como una tarea de clasificación, se utilizan las medidas de evaluación propias de tareas de clasificación para evaluar la conducta de nuestra propuesta. Los detalles de la experimentación son los siguientes.

**Partición de los datos** Se crean dos particiones diferentes de conjuntos de entrenamiento y de test para evaluar nuestra propuesta: (1) P1, el 80 % de las instancias se encuentran en

el conjunto de entrenamiento y el conjunto de test contiene el 20 % restante, y (2) P2, el 70 % de las instancias están en el conjunto de entrenamiento mientras que el 30 % restante están en el test.. El número de elementos de cada conjunto se muestra en el Tabla II.

**Emojis** Puesto que se considera que los *emojis* pueden ser una característica relevante para la tarea de desambiguación, comparamos resultados de: (1) eliminar los *emojis* de las instancias, y (2) sustituir cada *emoji* por una expresión textual.

**Entrenamiento de los modelos** Los valores de los hiperparámetros utilizados en los modelos neuronales se muestran en la Tabla III. El entrenamiento se llevó a cabo utilizando la función de pérdida de entropía cruzada y el algoritmo de optimización *Momentum* [32].

**Baseline** Con el fin de comparar, se aplica el modelo de clasificación *XGBoost* para bolsa de palabras [33]. *XGBoost* es un sistema de clasificación basado en árboles de decisión cuyo entrenamiento se basa en el método de aumento de gradientes. Los textos se *tokenizan* y las palabras se representan mediante su valor *tf-idf*.

**Métricas de evaluación** Dado que se re-formula la tarea de WSD como un problema de clasificación multiclase, se usan las versiones macro-promediadas de Precisión, Recall y F1.

### VI. RESULTADOS Y ANÁLISIS

En esta sección se describen y analizan los resultados alcanzados para el caso base, XGBoost, y los dos modelos presentados en la Sección III,  $\langle \overleftarrow{C}W^{t-k} \overrightarrow{C}W^{t+k} \rangle$  y  $\langle \overleftarrow{C}W^k \overrightarrow{C}W^{n-(k-1)} \rangle$ . En primer lugar se analiza y compara el rendimiento global de todos los modelos, y posteriormente se estudia el rendimiento por clase del mejor modelo. Finalmente, se analiza el impacto de eliminar o incluir *emojis* y el uso de *GloVe*.

La Tabla IV muestra los resultados alcanzados para los tres modelos indicados para cada partición de los datos incluyendo y sin incluir *emojis*. Los dos modelos neuronales superan al modelo XGBoost y logran resultados muy beneficiosos. Los mejores resultados para todos los modelos se obtienen en la partición P2 incluyendo *emojis*. Las mejores medidas para todas las particiones consideradas son proporcionadas por el modelo  $\langle \overleftarrow{C}W^k \overrightarrow{C}W^{n-(k-1)} \rangle$ , seguido por  $\langle \overleftarrow{C}W^{t-k} \overrightarrow{C}W^{t+k} \rangle$ .  $\langle \overleftarrow{C}W^{t-k} \overrightarrow{C}W^{t+k} \rangle$  alcanza peores resultados ya que considera menos información que  $\langle \overleftarrow{C}W^k \overrightarrow{C}W^{n-(k-1)} \rangle$ , debido a que

P1 entrenamiento	P1 test	P2 entrenamiento	P2 test
19.760	4.941	17.290	7.411

Tabla II  
TAMAÑO DEL CONJUNTO DE ENTRENAMIENTO Y TEST PARA P1 Y P2.

Hiperparámetro	Valor
Tamaño ventana de contexto ( <i>k</i> )	70
Dimensión <i>word embedding</i> ( <i>d</i> )	100
Unidades capa LSTM ( $h_{LSTM}$ )	74
Unidades capa Dense ( $h_{dense}$ )	200

Tabla III  
HIPERPARÁMETROS DE AMBOS MODELOS NEURONALES.

<sup>2</sup>[https://github.com/cristinazuhe/Disambiguation\\_SocialMedia\\_LSTM](https://github.com/cristinazuhe/Disambiguation_SocialMedia_LSTM).



## VII. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se propone una nueva arquitectura neuronal basada en el uso de las redes LSTM para la tarea de desambiguación de entidades, específicamente el modelo *Two k-Contextual Windows*. Además, se proporciona un nuevo corpus etiquetado para la desambiguación de la entidad *Granada* en textos extraídos de medios sociales, lo cuál es una aportación relevante para la comunidad investigadora.

En nuestra experimentación se pone en manifiesto que nuestro modelo propuesto logra resultados muy buenos en textos escritos en inglés extraídos de medios sociales. En contraste con [5], la codificación de la palabra a desambiguar contribuye a mejorar el rendimiento del sistema. Finalmente, tanto el uso de *embeddings* como la inclusión de expresiones para representar a los *emojis* permite alcanzar mejores resultados.

Como trabajo futuro, se desarrollarán nuevas técnicas para abordar el problema del desbalanceo de clases. Se trabajará en la creación de nuevos corpus de datos en otros idiomas con el objetivo de realizar experimentos en un entorno multilingüe.

## AGRADECIMIENTOS

Agradecemos a la empresa Mabrian por compartir los datos que han sido utilizados en la evaluación de nuestra propuesta. Este trabajo contó con el apoyo parcial del Ministerio de Economía y Competitividad de España en el marco del proyecto TIN2017-89517-P, y con una subvención del FEDER. Siham Tabik contó con el apoyo del Programa Ramón y Cajal (RYC-2015-18136) del Gobierno de España, y Eugenio Martínez Cámara fue apoyado por el Programa Juan de la Cierva Formación (FJCI-2016-28353) del Gobierno de España. En esta investigación usamos Titan X Pascal donada por NVIDIA Corporation.

## REFERENCIAS

- [1] M. T. Thai, W. Wu, and H. Xiong, *Big Data in Complex and Social Networks*. Chapman and Hall/CRC, 11 2016.
- [2] A. Farzindar and D. Inkpen, *Natural Language Processing for Social Media*, 2nd ed., ser. Synthesis Lectures on Human Language Technologies. Morgan & Claypool Publishers, 12 2017, vol. 10.
- [3] E. Agirre and P. Edmonds, *Word Sense Disambiguation: Algorithms and Applications (Text, Speech and Language Technology)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006.
- [4] R. Navigli, "Word sense disambiguation: A survey," *ACM Comput. Surv.*, vol. 41, no. 2, pp. 10:1–10:69, Feb. 2009.
- [5] M. Kägebäck and H. Salomonsson, "Word sense disambiguation using a bidirectional LSTM," in *Proceedings of the 5th Workshop on Cognitive Aspects of the Lexicon (CogALex - V)*. Osaka, Japan: The COLING 2016 Organizing Committee, December 2016, pp. 51–56.
- [6] E. Martínez-Cámara, M. T. Martín-Valdivia, L. A. Ureña López, and A. Montejo-Ráez, "Sentiment analysis in Twitter," *Natural Language Engineering*, vol. 20, no. 1, p. 1–28, 2014.
- [7] I. Iacobacci, M. T. Pilehvar, and R. Navigli, "Embeddings for word sense disambiguation: An evaluation study," in *Proceedings of the 54th Annual Meeting of the ACL (Vol 1: Long Papers)*, 2016, pp. 897–907.
- [8] M. Insall, T. Rowland, and E. W. Weistein, "Embedding." from mathworld—a wolfram web resource (access March 12, 2018), 2015.
- [9] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient estimation of word representations in vector space," *arXiv preprint:1301.3781*, 2013.
- [10] J. Pennington, R. Socher, and C. Manning, "Glove: Global vectors for word representation," in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing*. Doha, Qatar: ACL, October 2014, pp. 1532–1543.
- [11] Y. Goldberg, *Neural Network Methods for Natural Language Processing*. Morgan & Claypool Publishers, 2017.
- [12] R. Pascanu, T. Mikolov, and Y. Bengio, "On the difficulty of training recurrent neural networks," in *Proceedings of the 30th International Conference on Machine Learning - Volume 28*, ser. ICML'13. JMLR.org, 2013, pp. III–1310–III–1318.
- [13] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016, ch. 10.
- [14] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997.
- [15] A. Graves, "Supervised sequence labelling with recurrent neural networks," Ph.D. dissertation, Technische Universität München, 2008.
- [16] A. Raganato, J. Camacho-Collados, and R. Navigli, "Word sense disambiguation: A unified evaluation framework and empirical comparison," in *Proceedings of the 15th Conference of the European Chapter of the ACL: Volume 1, Long Papers*. ACL, 2017, pp. 99–110.
- [17] Z. S. Harris, "Distributional structure," *WORD*, vol. 10, no. 2-3, pp. 146–162, 1954.
- [18] J. R. Firth, "A synopsis of linguistic theory 1930-55," vol. 1952-59, pp. 1–32, 1957.
- [19] G. A. Miller and W. G. Charles, "Contextual correlates of semantic similarity," *LCP*, vol. 6, no. 1, pp. 1–28, 1991.
- [20] Z. Zhong and H. T. Ng, "It makes sense: A wide-coverage word sense disambiguation system for free text," in *Proceedings of the ACL 2010 System Demonstrations*. Uppsala, Sweden: ACL, July 2010, pp. 78–83.
- [21] H. Shen, R. Bunescu, and R. Mihalcea, "Coarse to fine grained sense disambiguation in wikipedia," in *Second Joint Conference on Lexical and Computational Semantics (\*SEM), Volume 1: Proceedings of the Main Conference and the Shared Task: Semantic Textual Similarity*. Atlanta, Georgia, USA: ACL, June 2013, pp. 22–31.
- [22] R. Collobert, J. Weston, L. Bottou, M. Karlen, K. Kavukcuoglu, and P. Kuksa, "Natural language processing (almost) from scratch," *Journal of Machine Learning Research*, vol. 12, pp. 2493–2537, Nov. 2011.
- [23] C. D. Santos and B. Zadrozny, "Learning character-level representations for part-of-speech tagging," in *Proceedings of the 31st International Conference on Machine Learning*, E. P. Xing and T. Jebara, Eds., vol. 32, no. 2, 2014, pp. 1818–1826.
- [24] E. Kiperwasser and Y. Goldberg, "Simple and accurate dependency parsing using bidirectional lstm feature representations," *Transactions of the ACL*, vol. 4, pp. 313–327, 2016.
- [25] D. F. Wong, Y. Lu, and L. S. Chao, "Bilingual recursive neural network based data selection for statistical machine translation," *Knowledge-Based Systems*, vol. 108, pp. 15 – 24, 2016, new Avenues in Knowledge Bases for Natural Language Processing.
- [26] K. Lin, D. Li, X. He, M.-t. Sun, and Z. Zhang, "Adversarial ranking for language generation," in *Advances in Neural Information Processing Systems 30*, I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, Eds. Curran Associates, Inc., 2017, pp. 3158–3168.
- [27] O. Melamud, J. Goldberger, and I. Dagan, "context2vec: Learning generic context embedding with bidirectional lstm," in *Proceedings of the 20th SIGNLL Conference on Computational Natural Language Learning*. ACL, 2016, pp. 51–61.
- [28] K. Taghipour and H. T. Ng, "Semi-supervised word sense disambiguation using word embeddings in general and specific domains," in *Proceedings of the 2015 Conference of the North American Chapter of the ACL: Human Language Technologies*. Denver, Colorado: ACL, May–June 2015, pp. 314–323.
- [29] A. Kilgarriff, "English lexical sample task description," in *The Proceedings of the Second International Workshop on Evaluating Word Sense Disambiguation Systems*. ACL, 2001, pp. 17–20.
- [30] R. Mihalcea, T. Chklovski, and A. Kilgarriff, "The senseval-3 english lexical sample task," in *Proceedings of senseval-3, the third international workshop on the evaluation of systems for the semantic analysis of text*, 2004.
- [31] J. Read, "Using emoticons to reduce dependency in machine learning techniques for sentiment classification," in *Proceedings of the ACL Student Research Workshop*. ACL, 2005, pp. 43–48.
- [32] N. Qian, "On the momentum term in gradient descent learning algorithms," *Neural Networks*, vol. 12, no. 1, pp. 145 – 151, 1999.
- [33] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ser. KDD '16. New York, NY, USA: ACM, 2016, pp. 785–794.



# Detección de nodos tramposos en procesos de consenso en redes

M. Rebollo\*<sup>†</sup>

\*Grupo de Tec. Informática – Inteligencia Artificial  
Universitat Politècnica de València  
Valencia, Spain  
mrebollo@upv.es

R.M. Benito<sup>†</sup>, J.C. Losada<sup>†</sup>, J. Galeano<sup>†</sup>

<sup>†</sup>Grupo de Sistemas Complejos  
Universidad Politécnica de Madrid  
Madrid, Spain  
{rosa.benito, juancarlos.losada, javier.galeano}@upm.es

**Resumen**—Los procesos de consenso en redes son procesos de difusión de información que permiten realizar cálculos de forma distribuida en una red, intercambiando información únicamente con los vecinos directos y sin tener conocimiento global de la estructura, tamaño, valores ni otras características de la red. Sin embargo, este proceso requiere que todos los nodos sigan el mismo algoritmo y cualquier cambio provoca una alteración en el valor de consenso alcanzado. Este trabajo propone un modelo para la detección de nodos que de forma deliberada o accidental no siguen el proceso de consenso. La red podrá, de forma autónoma y no supervisada, detectar estas desviaciones y corregirlas. Se muestra su aplicación a tres escenarios: un sistema de voto distribuido, la manipulación de imágenes por *adversarial examples* y el problema de los generales bizantinos, que es la base de los protocolos usados para la manipulación de cadenas de bloques.

**Index Terms**—complex networks, consenso, votaciones, blockchain, adversarial examples, tolerancia a fallos, resiliencia

## I. INTRODUCCIÓN

Los procesos de consenso en redes permiten calcular de forma distribuida el valor de una función común. Cada nodo emplea únicamente sus datos y la información de sus vecinos directos para recalcularse de forma iterativa el valor de la función y propagarlo a través de sus vecinos. Este proceso converge a un valor único final para la función que se está calculando. Los nodos no tienen ningún tipo de conocimiento sobre el tamaño, la topología de la red ni ninguna otra característica.

Sea  $G = (V, E)$  un grafo no dirigido formado por un conjunto de vértices  $V$  y un conjunto de enlaces  $E \subseteq V \times V$  donde  $(i, j) \in E$  si existe un enlace entre los nodos  $i$  y  $j$ . Un vector  $x = (x_1, \dots, x_n)^T$  contiene los valores iniciales de las variables asociadas a cada nodo de la red. Olfati–Saber and Murray [1] proponen un algoritmo cuya aplicación iterativa converge al valor medio de  $x$ . La convergencia de este método está asegurada.

$$x_i(t+1) = x_i(t) + \varepsilon \sum_{j \in N_i} [x_j(t) - x_i(t)] \quad (1)$$

Este proceso converge al valor medio de los valores iniciales

$$\lim_{t \rightarrow \infty} x(t) = \frac{1}{n} \sum_i x_i(0) = \bar{x} \quad (2)$$

This work is supported by the PROMETEOII/2013/019, TIN2015-65515-C4-1-R and MTM2015-63914-P projects of the Spanish government

y en todas las iteraciones se conserva la suma de  $x$ .

$$\sum_i x_i(0) = \sum_i x_i(t) \quad \forall t \leq 0 \quad (3)$$

Sin embargo, algunas funciones no pueden calcularse por este proceso. Particularmente, aquellas que requieren la consideración de valores repetidos (como la moda) o valores acumulados (por ejemplo, obtener la suma de los valores iniciales). Por otra parte, todos los nodos deben seguir exactamente el proceso de forma obligatoria para que el resultado sea correcto. Para alterar el resultado, basta con que uno de los nodos altere el valor que intercambia en una de las iteraciones para que el valor de consenso se desvíe del valor esperado. Existen mecanismos para detectar cuándo se produce una variación, pero requieren guardar el estado completo de la red en cada iteración y además es necesario mantener una visión global de la red y conocer su estructura, pues se basan en matrices de observación que se calculan a partir de la matriz de adyacencia de la red completa [2]. Otras alternativas requieren la existencia de un nodo que hace las funciones de coordinador [3]. También están relacionados otros trabajos enfocados a reducir el efecto del ruido en redes de sensores, pero sus soluciones están centradas en obtener la topología de red óptima para minimizar el efecto del ruido [4], [5]

En el presente trabajo se propone un método completamente descentralizado que no requiere información global de la red y que es independiente de la topología, si bien es cierto que existen determinadas restricciones que se deben cumplir para poder anular por completo las desviaciones producidas.

Para mostrar su utilidad, se aplica a tres casos: un mecanismo de voto distribuido, la difusión de imágenes a través de una red y el problema de los generales bizantinos, que es la base de las cadenas de bloques. En todos ellos nos centraremos en cómo detectar y corregir las posibles manipulaciones sobre el proceso de consenso para alterar el resultado de la votación, modificar la imagen para que no se clasifique correctamente (usando *adversarial example*) o evitar la difusión de mensajes falseados en el caso de los generales.

## II. DETECCIÓN DE DESVIACIONES EN EL PROCESO DE CONSENSO

El proceso de consenso definido en (1) asume que todos los participantes ejecutan el mismo algoritmo. Si un nodo desea

alterar el resultado basta con enviar a los vecinos cualquier otro valor. Por ejemplo, si un nodo  $i$  envía un valor fijo  $x_i(t) = x_i(0) \forall t$ , la red completa convergerá a dicho valor  $x_i(0)$ . En general, podemos modelar el proceso de consenso con desviaciones como

$$x_i(t+1) = x_i(t) + \varepsilon \sum_{j \in N_i} [x_j(t) - x_i(t)] + u_i(t) \quad (4)$$

donde  $u_i(t)$  es el error introducido por el nodo  $i$  en la iteración  $t$ . La pregunta que se plantea es si los vecinos de  $i$  pueden detectar cuándo  $u_i(t) \neq 0$ .

### II-A. Detección de fallos en el protocolo

Despejando (1) podemos obtener la siguiente expresión:

$$dv_i(t+1) = x_i(t+1) + (\varepsilon d_i - 1)x_i(t) - \varepsilon \sum_{j \in N_i} x_j(t) \quad (5)$$

siendo  $d_i$  el grado del nodo  $i$ . Si los nodos de la red siguen el algoritmo, cada iteración debe cumplir

$$dv_i(t) = 0 \quad \forall t \geq 0 \quad (6)$$

y cuando  $dv_i(t) > 0$  el nodo puede cuestionar la validez de los datos recibidos. La primera parte de la expresión depende solo de los valores de  $i$  y el último término es la suma de los valores recibidos en la iteración anterior, así que basta con guardar esta suma para controlar el proceso. La única restricción del método es que el primer intercambio debe ser el real, es decir, el valor inicial no contendrá errores.

De esta manera se detecta que el resultado obtenido en el proceso de consenso no es correcto. La siguiente pregunta que se plantea es ¿puede corregirse esta desviación?

### II-B. Corrección de las desviaciones

Una primera aproximación es compensar la desviación cuando se detecta en los nodos de la red. Vamos a asumir, sin perder generalidad y para facilitar la explicación, que la desviación se produce una única vez y en uno de los nodos  $i$ . Todos sus vecinos  $j \in N_i$  lo detectan según (5), con  $dv_j(t) > 0$ . En la siguiente iteración, estos nodos descuentan la desviación de su valor calculado, haciendo

$$z_j(t+1) = x_j(t+1) - dv_j(t+1) \quad (7)$$

siendo  $z_j(t+1)$  el valor a intercambiar en la siguiente iteración. Si todos los nodos se comportan de esta forma, la suma se conserva y además se puede demostrar que  $u(t) = \sum_i dv_i(t+1)$ . El principal problema de esta solución es que el nodo que introduce la desviación debe colaborar para compensar el resultado, lo que no es probable.

De (5) se puede deducir cómo se reparte el exceso entre los vecinos. El nodo tramposo  $i$  se guarda  $(1 - \varepsilon d_i)u_i(t)$  para él mismo y reparte  $\varepsilon u_i(t)$  para cada uno de sus vecinos, luego

$$dv_j(t+1) = \varepsilon \sum_{k \in N_j} u_k(t), \quad \frac{dv_j(t+1)}{\varepsilon} = \sum_{k \in N_j} u_k(t) \quad (8)$$

Dividiendo la desviación obtenida en el nodo por el factor  $\varepsilon$ , cualquier nodo conoce cuál es el error total que se ha introducido en el consenso. Sin embargo, dado que los valores de  $\sum_{k \in N_j} u_k(t)$  están agregados, lo que no es posible es determinar qué nodo ha introducido el error.

Esta solución permite a los vecinos del nodo con la desviación saber que algo está mal en el proceso de consenso y corregirlo. Para que esta corrección llegue a todos los nodos se debe propagar también por la red, por lo que se efectúa un proceso de consenso paralelo

Es importante destacar que este método no impide la manipulación ni lo corrige cuando lo detecta. El proceso converge al valor manipulado. Sin embargo, cuando finaliza el proceso, los nodos disponen de la información necesaria para saber si se ha producido alguna desviación de los datos y cómo corregirla.

## III. CASOS DE APLICACIÓN

A continuación se van a presentar tres casos de aplicación de la detección y corrección de fallos a problemas para los que disponer de sistemas robustos y seguros es de vital importancia: (i) un sistema de votación electrónica, (ii) la detección de imágenes manipuladas mediante *adversarial examples* y (iii) el problema de los generales bizantinos, base de las cadenas de bloques.

### III-A. Votación distribuida

Supongamos que se desea obtener el resultado de una votación que se realiza de forma distribuida en una red. Supongamos que se dispone de  $m$  opciones y cada nodo solo puede votar a una de ellas. El proceso de consenso consistirá en intercambiar con los vecinos un vector  $x_i = (x_i^1, \dots, x_i^m)$ , donde  $x_i^k = 1$  si  $k$  es la opción seleccionada por  $i$  and  $x_i^j = 0 \forall j \neq k$ . Es decir, el vector contiene un 1 en la posición de la opción votada y ceros en todas las demás. Cuando se realiza el proceso de consenso, el resultado converge al valor medio de la votación. Para obtener el resultado general, basta con multiplicar el resultado por el número de nodos, que puede obtenerse de forma sencilla con un proceso de consenso en paralelo inicializado de una forma particular.

El proceso de consenso converge a la media de los valores iniciales. Si  $\sum_i y_i(0) = 1$ , el proceso de consenso convergerá para algún instante de tiempo  $t$  a  $y_i(t) = \frac{1}{n}$  por lo que el tamaño de la red  $n = \frac{1}{y_i(t)}$ . Ambos procesos de consenso son independientes y pueden ejecutarse en paralelo.

Extendemos el vector de votos con una columna adicional

$$(x_i | y_i) = (x_i^1, \dots, x_i^m | y_i) \quad (9)$$

e, inicialmente,  $y_i = 0 \forall i$ . Sin perder generalidad, podemos introducir un nodo adicional en la red cuyos valores iniciales sean

$$(x_0 | y_0) = (\underbrace{0, \dots, 0}_m | 1) \quad (10)$$

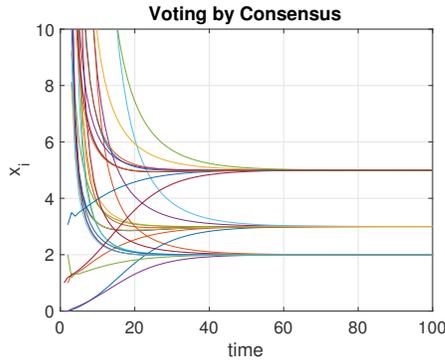


Figura 1. Evolución del proceso de consenso para calcular el resultado de una votación de forma distribuida. red aleatoria con  $n = 10$  nodos y  $m = 3$  opciones. Los votos son  $x(0) = \{3, 3, 1, 3, 2, 1, 1, 2, 3, 3\}$ , lo que da un resultado de  $\{3, 2, 5\}$ .

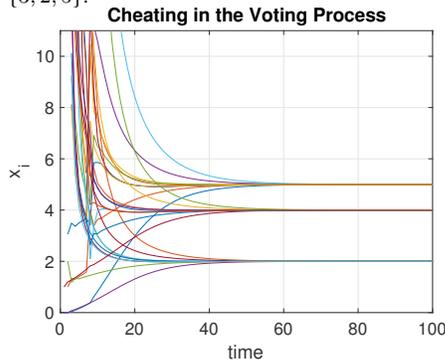


Figura 2. El nodo  $i = 7$  añade 2 votos a la primera opción y elimina un voto de la tercera en la iteración  $t = 6$ . El resultado alterado converge a  $\{5, 2, 4\}$ .

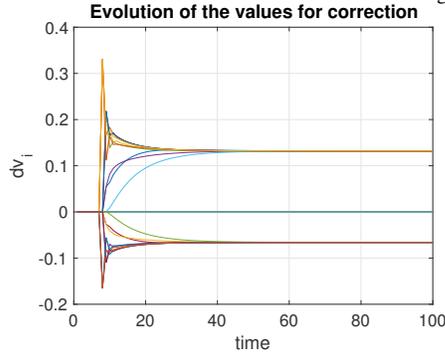


Figura 3. El proceso de consenso sobre las desviaciones detectadas converge a  $dv(t) = (0, 1320, 0, -0, 0660)$ . Aplicando (8) adaptada a votaciones, con  $\varepsilon = 0, 1650$  y  $w = 0, 4$  se obtiene la corrección deseada  $\frac{dv/\varepsilon}{w} = (2, 0, -1)$

Este nodo no afecta al resultado de la votación puesto que no vota por ninguna opción. Cuando el proceso de consenso converge, basta con que cada nodo divida los valores finales  $x_i$  por el valor obtenido en la última columna  $y_i$  para determinar el resultado general de la votación tal y como muestra (11)

$$\begin{aligned} \frac{x_i(t)}{y_i(t)} &= \frac{(x^1, \dots, x^m)}{1/n} = (nx^1, \dots, nx^m) \\ &= \left( \sum_j x_j^1, \dots, \sum_j x_j^m \right) \end{aligned} \quad (11)$$

La Figura 1 muestra un ejemplo de la aplicación de este

proceso sobre una red aleatoria de diez nodos. Los nodos eligen entre 3 opciones y la elección de cada uno es  $x(0) = \{3, 3, 1, 3, 2, 1, 1, 2, 3, 3\}$ . Por lo tanto,  $(x_1|y_1) = (0, 0, 1|0)$ ,  $(x_2|y_2) = (0, 0, 1|0)$ ,  $(x_3|y_3) = (1, 0, 0|0)$ , y así sucesivamente. Las líneas muestran la evolución del cociente  $\frac{x_i^k(t)}{y_i(t)}$ . Puede observarse que la red converge al resultado de la votación  $\{3, 2, 5\}$ .

Supongamos que el nodo  $i = 7$  desea añadir dos votos a la primera opción y eliminar un voto de la tercera:  $u_7 = (2, 0, -1)$ . El resultado del consenso convergerá a  $\{5, 2, 4\}$  y la opción ganadora sería la primera, tal y como deseaba el nodo 7 (ver Figura 2). Aplicando (5), la red puede detectar esta manipulación. La Figura 3 muestra el proceso de consenso sobre los valores de  $dv_i(t)$ . Para corregir las desviación en el proceso de voto, el consenso de las desviaciones también se extiende con un valor  $w_i$  adicional que en este caso se emplea para determinar cuántos nodos han detectado la desviación. El resultado obtenido al aplicar (8) debe dividirse por este valor  $w_i$ . En el caso de la Figura 3,  $\varepsilon = 0, 1650$  y la manipulación es detectada por cuatro nodos, lo que arroja un valor de  $w = 0, 4$ , con lo que la desviación detectada a partir de los valores de  $dv(t)$  obtenidos será  $(2, 0, -1)$  en todos los nodos.

De esta forma, al terminar el proceso de consenso, aunque el resultado esté manipulado, todos los nodos de la red tienen la información que les permite corregirlo.

### III-B. Adversarial examples

Un segundo caso de aplicación es la transmisión de imágenes a través de una red. Asumiremos que hay un nodo que tiene la imagen (por ejemplo, una imagen capturada en una cámara, como la matrícula de un coche) y quiere propagarla a todos los demás. Sin perder generalidad, será  $i = 1$ .

La representación de la imagen será a través de un vector que contiene el mapa de bits, con tantos elementos como resolución tiene la imagen y con el valor de RGB de cada pixel. El proceso de consenso se debe modificar de forma semejante al apartado anterior. A dicho vector, se le añade una columna  $y_i$  que valdrá cero para todos los nodos excepto para el que contenga la imagen, para el que  $y_1 = 0$ . Si la imagen contiene  $p$  píxeles,  $(x_1|y_1) = (x_1^1, \dots, x_1^p | 1)$  y para el resto de nodos  $(x_i|y_i) = (0, \dots, 0 | 0)$ . Cuando el proceso de consenso converge, basta con dividir el valor obtenido para cada pixel entre  $y_i(t)$  para recuperar la imagen original.

Sin embargo, un nodo malicioso puede tratar de modificar la imagen para que el sistema no la reconozca o la identifica erróneamente. Una de las técnicas empleadas se conoce como *adversarial example* [6] y consiste en añadir a la imagen una ligera distorsión de manera que los algoritmos de *deep learning* fallen y clasifiquen la imagen de forma incorrecta (ver Figura 4).

En este caso, el nodo  $i = 5$  aplica una perturbación a la imagen en la iteración  $t = 20$ , tal y como muestra la Figura 4. A la perturbación se le aplica un factor de 0.007, que es suficiente para hacer que los clasificadores que no contemplan *adversarial example* fallen, aunque para el ojo humano parece que la imagen no ha sido alterada. La



Figura 4. Adversarial example. Si a la imagen de la derecha (panda) se le añade la perturbación (centro), da como resultado una imagen que es erróneamente clasificada como un gibón (derecha)

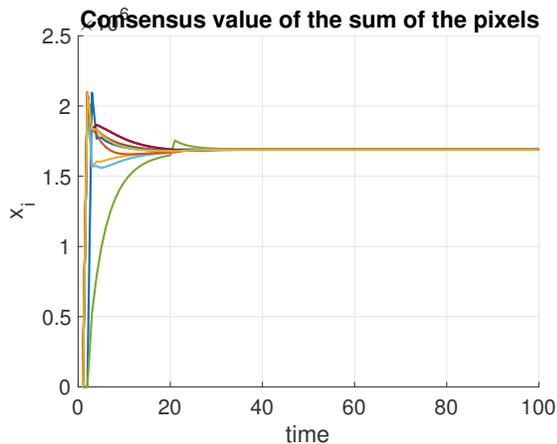


Figura 5. Alteración del consenso en la iteración 20 para incluir la imagen modificada para *adversarial example*. El valor de  $x_i$  es la suma del mapa de bits asociado a la imagen

Figura 5 muestra el proceso de consenso, donde el valor es la suma del mapa de bits asociado a la imagen. Se aprecia la perturbación introducida. Cuando converge, todos los nodos tienen la imagen alterada.

Pero de la misma forma que en el caso de la votación, la alteración se detecta inmediatamente por los vecinos utilizando (8) y esta desviación respecto a la imagen original se puede corregir cuando el proceso ha finalizado.

En esta ocasión, vamos a relajar la corrección, de manera que no deseamos recuperar la imagen original, si no simplemente tratar de paliar el efecto de la perturbación para que la imagen vuelva a ser clasificada correctamente. El resultado que muestra la Figura 6 se ha obtenido haciendo un consenso sobre las desviaciones  $dv_i$  obtenidas. De esta forma, la parte de la perturbación que se queda el nodo que modifica la imagen  $\varepsilon(1 - d_i)u_i(t)$  no se puede recuperar.

Pero como se puede ver de los resultados de la Tabla I, aunque no se recupere la imagen original, la corrección es lo suficientemente buena como para que la imagen vuelva a ser correctamente clasificada.

Los métodos actuales suelen incorporar bibliotecas que incorporan el *adversarial example*, por lo que frecuentemente



Figura 6. *Adversarial example*. Imagen corregida después del proceso de consenso. Se clasifica como panda con una precisión del 0.9986 (googleNet)

el único efecto que tiene es disminuir la precisión del clasificador en la imagen seleccionada, pero sigue clasificándose de forma correcta. La imagen corregida por consenso muestra un pixelado mayor, perceptible a simple vista (Figura 6) Sin embargo, la precisión que obtiene por el clasificador es equivalente a la imagen original. La implementación de los distintos algoritmos corresponden a las versiones de Matlab para la *Neural Network Toolbox*. En todos los casos excepto VGG-16, las imágenes son clasificadas como panda gigante, la imagen modificada obtiene una menor precisión y la imagen corregida, sin ser una corrección total, logra resultados comparables a la imagen original. En el caso de VGG-16, se observa el comportamiento detectado en el trabajo de Goodfellow [6] y la imagen manipulada se clasifica como un gibón. La corrección vuelve a clasificarse correctamente, y esta vez con una precisión notablemente superior.

### III-C. Problema de los generales bizantinos

Un tercer caso de aplicación de particular interés: el problema de los generales bizantinos. La primera solución la plantean Lamport et al. [7] y propone una solución basada en prueba de trabajo (*proof of work -POW-*) como las que incorporan en la actualidad los algoritmos para cadenas de bloques y algunas criptomonedas, como bitcoin.



Cuadro I

PRECISIÓN DE LA CLASIFICACIÓN DE IMÁGENES POR DISTINTOS ALGORITMOS. LA TABLA MUESTRA LA PRECISIÓN DE LA IMAGEN ORIGINAL, LA IMAGEN MODIFICADA POR *adversarial example*, Y LA IMAGEN CORREGIDA DURANTE EL PROCESO DE CONSENSO.

	Google Net	Res-Net 50	Alex Net	VGG-16
original	0.9873	0.9844	0.7479	0.5715 (panda)
alterada	0.9313	0.9429	0.6887	0.4439 (gibón)
corregida	0.9986	0.9863	0.9220	0.8302 (panda)

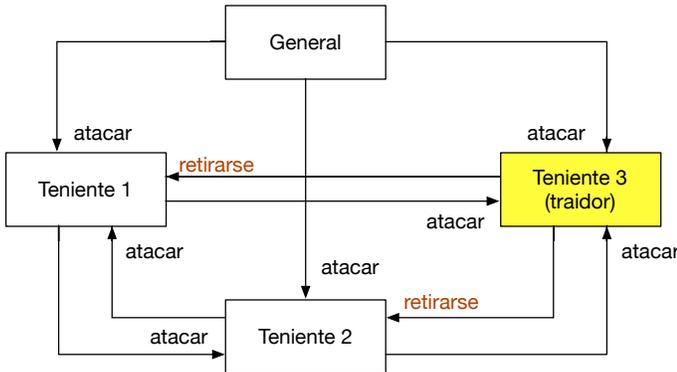


Figura 7. Problema de los generales bizantinos con 4 generales y con un mensaje simple de atacar o retirarse. Los generales solo atacarán si están seguros de que van a hacerlo todos.

El problema de los generales bizantinos consiste en lo siguiente. Supongamos que un conjunto de generales están sitiando una ciudad y tienen que coordinarse para atacar. Si no lo hacen todos al mismo tiempo, fracasarán. Dentro del grupo hay algunos generales traidores que tratarán de prevenir el acuerdo. Para poder atacar, uno de los generales mandará un mensaje al resto (los llamaremos tenientes para diferenciarlos) con la hora a la que van a atacar o indicando si se van a retirar. Cada teniente leal transmitirá el mensaje tal y como lo ha recibido, Pero los traidores alterarán el mensaje indicando una hora distinta. Por ejemplo, si el ataque es a las 9:00, un general traidor mandará un mensaje para que el ataque sea a las 8:00. Cuando lleguen las 8:00, los generales que hayan sido engañados atacarán y, al no ser suficientes, perderán. Luego, los generales restantes atacarán a las 9:00 y de nuevo perderán por no ser suficientes.

¿Cómo puede el algoritmo de consenso resolver este problema? En primer lugar, veamos cómo se pueden sincronizar mediante consenso. Supongamos que no hay traidores. La inicialización será la siguiente: el general (nodo  $i = 1$ ) la hora de ataque como valor inicial  $x_1(0) = 8$  y la columna adicional con  $y_1 = 1$ , con un vector extendido  $(x_1|y_1) = (8 | 1)$ . El resto de nodos se inicializan a cero:  $(x_i|y_i) = (0 | 0), \forall i \neq 1$ . Una vez alcanzada la convergencia, todos los generales sabrán la hora de ataque, que será  $\frac{x_i(t)}{y_i(t)} = 8$ .

Si hay algún traidor, como muestra la Figura 8, la red converge al valor modificado. En este caso, el nodo  $i = 15$  a incrementado en una la hora de ataque y la red converge a 9.

En este caso necesitamos obtener la hora precisa, por lo que es necesario hacer una corrección completa siguiendo (8). De

esta forma, los generales determinan que la hora recibida de ataque tiene una desviación de 1 hora adicional sobre la hora que contenía el mensaje original, luego la hora de ataque serán las 8:00 (Figura 9).

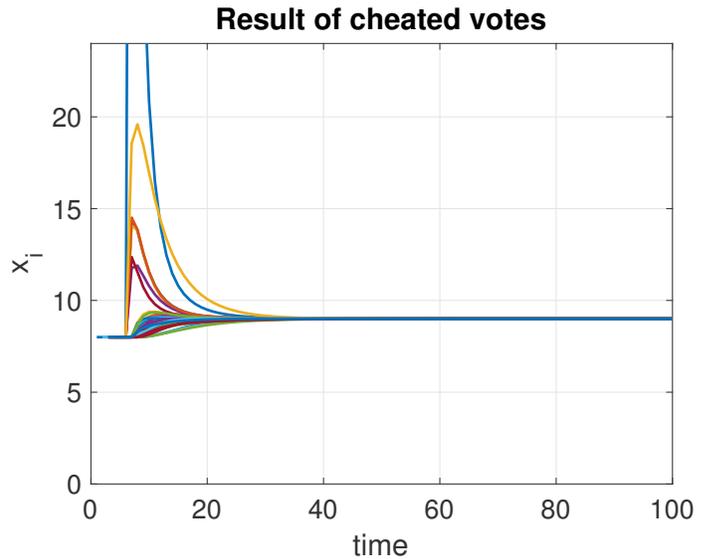


Figura 8. Proceso de consenso para determinar la hora de ataque en una red aleatoria de 50 nodos. El nodo  $i = 15$  es un traidor y cambia la hora de ataque de las 8:00 a las 9:00.

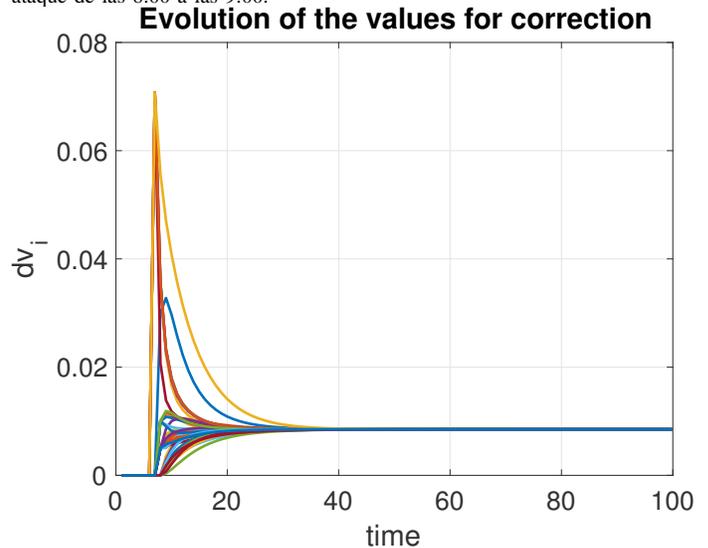


Figura 9. Evolución del factor de corrección  $dv_i(t)$ . El valor de convergencia es de 0.0085 y aplicando (8) se obtiene que la diferencia con la hora de ataque tiene un exceso de 1 hora

### III-D. Validación en redes sintéticas

Finalmente, se han realizado un conjunto de experimentos para validar cómo se degrada la solución a medida que aumentan los nodos que no siguen el algoritmo de consenso. Las pruebas se han realizado sobre redes aleatorias de 100 nodos. Se ha variado el número de nodos que no siguen el proceso desde 5 hasta 50 (representa el 50% de la red). Para cada caso, se han generado 20 redes diferentes y en cada una de ellas se han ejecutado 50 experimentos variando qué nodos

hacen trampas, con un total de 1000 ejecuciones para cada caso. En la Figura 10 se muestra el valor medio (la línea central) y la desviación típica (el área sombreada). Puede verse que siempre hay una desviación mínima, debido a la ubicación de los nodos tramosos.

Para que la solución de Lamport para problema de los generales bizantinos o la corrección planteada por Sundaram funcionen, se requiere que

1. en la red haya al menos  $3m + 1$  nodos si hay  $m$  nodos tramosos
2. al menos la mitad de los vecinos de cada nodo deben comportarse correctamente

Puesto que para estas pruebas se han generado redes aleatorias sin ningún control sobre el tipo de nodos y su conectividad, y que los ejemplos llegan a una distribución de nodos de confianza y tramosos de 50–50, es de esperar que haya casos en los que la red no sea capaz de compensar la desviación. Resulta interesante ver que el proceso de consenso sigue funcionando aunque se supere el límite de un tercio de nodos tramosos, si bien es algo que debe estudiarse en más profundidad y queda para trabajos futuros.

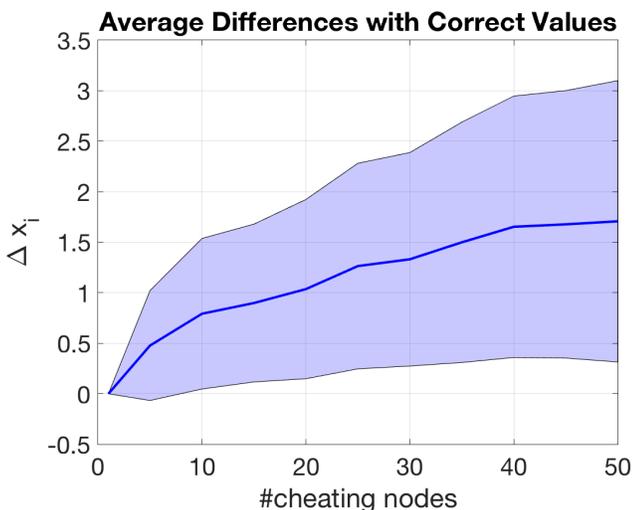


Figura 10. Desviaciones sin corregir en una red de 100 nodos variando el número de nodos tramosos. La línea central es el valor medio y el área sombreada la desviación típica.

#### IV. CONCLUSIONES

Los procesos de consenso en redes nos permiten realizar cálculos distribuidos sobre el valor de cierta función sobre los valores iniciales de la red, como la media, máximos, mínimos o valores agregados, utilizando tan solo información local y sin conocer la topología ni ninguna otra característica de la red. Sin embargo, para que el proceso funcione, todos los nodos están obligados a seguir el mismo algoritmo. Si tan solo uno de ellos realiza un cambio en uno de los pasos, el valor al que

converge la red se ve alterado. Para evitarlo, en el presente trabajo ha desarrollado un mecanismo que permite (i) detectar cuándo se produce una desviación en el proceso de consenso y (ii) corregir la desviación sobre el valor final obtenido.

Se ha mostrado su utilidad en tres problemas de interés: un sistema de votación distribuido, la alteración de imágenes usando *adversarial example* y la resolución del problema de los generales bizantinos. En todos ellos, se ha realizado una adaptación del proceso de consenso para poder hacer cálculos sobre valores agregados, aprovechando la asignación concreta de los valores iniciales y realizando un consenso doble en paralelo sobre variables independientes. En los tres casos, se ha aplicado con éxito el algoritmo de consenso con detección de desviaciones. En el caso de las votaciones, se evita que un nodo intente añadir o eliminar votos a alguna de las opciones. Para la difusión de imágenes, se pueden anular los efectos en los errores de clasificación de imágenes a las que se les ha introducido una perturbación mediante *adversarial example*. Finalmente, en el problema de los generales bizantinos se corrigen los cambios que los traidores hacen en los mensajes y se recupera la hora original. De esta manera, se consigue un método robusto que permite seguir aplicando el consenso en situaciones de incertidumbre, en las que se pueden producir fallos de forma accidental o deliberada y los valores que se transmiten no son los correctos.

Una limitación del método expuesto es que los nodos necesitan tener un número mínimo de vecinos de confianza que propague la información siguiendo el algoritmo. La cantidad de nodos tramosos no debe superar un tercio del total de nodos de la red. Los resultados obtenidos experimentalmente indican que utilizando procesos de consenso se pueden reducir estos límites, pero es necesario un estudio teórico en profundidad sobre el comportamiento del algoritmo presentado. Por otra parte, no se contempla la posibilidad de que los nodos tramosos coordinen sus ataques. Se asume que cada nodo intenta afectar el resultado de forma individual frente a toda la red. Un planteamiento que resuelva estas situaciones se contempla como trabajo futuro.

#### REFERENCIAS

- [1] R. Olfati-Saber and R. M. Murray, *Consensus problems in networks of agents with switching topology and time-delays* IEEE TAC. **49**(9), 1520–1533 (2004)
- [2] S. Sundaram, S., and C.N. Hadjicostis, *Distributed function calculation via linear iterative strategies in the presence of malicious agents*. IEEE TAC, **56**(7), 1495–1508 (2011)
- [3] M. Rafailescu, *Fault Tolerant Leader Election In Distributed Systems*. IJCSIT, **9**(1), 13–20 (2017)
- [4] Ma, C., Li, T. and Zhang, J., *Consensus control for leader-following multi-agent systems with measurement noises*. J Syst Sci Complex **23**(1), 35–49 (2010)
- [5] Wang, J.Z., Mareels, I. and Tan, Y. *Robustness of Distributed Multi-Agent Consensus*, IFAC Proceedings Volumes **41**(2), 1510–1515 (2016)
- [6] Goodfellow, Ian, Shlens, Jonathon and Szegedy, Christian. *Explaining and Harnessing Adversarial Examples*. arXiv 1412.6572. (2014)
- [7] Lamport, L. and Shostak, R. and Pease, M. *The Byzantine Generals Problem*. ACM TPLS, **4**(3), 382–401 (1982)



# Resumiendo Opiniones Negativas con *Deep Learning* y Reglas Descriptivas

Ana Valdivia, Eugenio Martínez-Cámara, M. Victoria Luzón, Francisco Herrera  
 Instituto Andaluz de Investigación en Ciencia de Datos e Inteligencia Computacional  
 Universidad de Granada, 18014 Granada, España  
 Email: avaldivia@ugr.es, emcamara@decsai.ugr.es, luzon@ugr.es, herrera@decsai.ugr.es

**Resumen**—La tarea del Análisis de Opiniones a Nivel de Aspecto se basa en realizar un análisis sobre las opiniones con el mayor detalle posible, pues detecta aspectos específicos que aparecen en el texto de la opinión. No obstante, debido a que la información que se extrae de estos algoritmos es muy precisa, aspecto por aspecto, ésta no contribuye a obtener un conocimiento general de todo el corpus. Por ello, en este trabajo se propone una metodología que, a partir de la extracción de aspectos, se resume todo el contenido de una manera descriptiva, visualizando las conexiones más relevantes entre aspectos y una cierta polaridad, que en nuestro caso es la negativa. En este estudio, demostramos que este nuevo método puede emplearse para obtener una descripción global de un corpus entero a partir de las relaciones más significativas entre un aspecto y su polaridad.

## I. INTRODUCCIÓN

El Análisis de Opiniones (AO), que tiene como objetivo extraer sentimientos de textos escritos [1], ha alcanzado un alto interés en la sociedad debido a la gran cantidad de textos generados por usuarios que existen en blogs, foros, redes sociales, etc. Dentro de este campo, existen diferentes niveles de análisis dependiendo de su granularidad. El Análisis de Opiniones a Nivel de Aspecto (AONA)<sup>1</sup> es considerado el nivel más profundo de análisis [2]. Todos los métodos basados en AONA tienen como objetivo detectar polaridades en entidades y aspectos mencionados en el texto. Esta subtarea del AO se ha viralizado en los últimos años debido a su capacidad de extraer información muy fina y detallada.

No obstante, los métodos de AONA trabajan a nivel de entidad, lo que implica que la información que extraen es específica de cada opinión que analiza. Permiten obtener un análisis muy preciso de cada opinión, por lo que la información que se extrae a partir de estas técnicas es muy local.

Debido a ello, en este trabajo se propone una nueva metodología que extrae información general de las opiniones a través de algoritmos basados en AONA. La idea es mejorar la capacidad de generalización mediante Reglas Descriptivas (RD) que muestran las relaciones más relevantes entre los aspectos y polaridades. El proceso se basa en tres fases: (1) Extracción de aspectos de las opiniones, (2) Agrupación de aspectos que se refieren a conceptos similares y (3) Extracción de reglas descriptivas de aspectos y polaridades.

Los experimentos están centrados en las opiniones en inglés de TripAdvisor de tres monumentos culturales: la Alhambra,

la Sagrada Familia y la Mezquita de Córdoba. El propósito es el de caracterizar el conjunto de todas las opiniones negativas de estos monumentos, encontrando los aspectos más relevantes de esta clase, pues son los que ayudan a entender qué entidades se podrían mejorar de la visita. Los resultados muestran claramente que la metodología es eficaz para abordar la falta de generalización de los algoritmos AONA, y más específicamente, podría ser utilizado por el personal gerente de monumentos culturales para mejorar la experiencia de la visita cultural.

La estructura de este trabajo sigue así: la Sección II presenta una breve introducción de los conceptos básicos para una mejor comprensión de este estudio. La Sección III presenta la metodología propuesta para abordar el problema identificado. La Sección IV muestra los experimentos realizados. Finalmente, la Sección V resume las conclusiones del trabajo y propone futuras líneas de investigación.

## II. CONTEXTO

En esta sección se describen los conceptos generales en los que se basa esta metodología. Primero, se define AONA (Sección II-A), luego, se describen los algoritmos que existen basados en *Deep Learning* (DL) para AONA. Finalmente, se presentan las reglas descriptivas (Sección II-C).

### II-A. Análisis de Opiniones a Nivel de Aspecto (AONA)

AONA es una subtarea de AO que se basa en extraer aspectos y polaridades de entidades que son nombradas en opiniones. Es una tarea que aporta información granular del propósito de la opinión [3], y por lo tanto también es más precisa, ya que los usuarios no suelen mostrar el mismo sentimiento en todo un mismo texto. Por ejemplo, si analizamos el siguiente enunciado:

*“Los jardines de la Alhambra son espectaculares, pero las colas que se forman antes de entrar son horribles (deberían mejorar el sistema de entradas).”*

En el ejemplo se observa que la usuaria primero expresa un sentimiento positivo hacia los jardines, pero luego critica el sistema de entradas por las colas que se forman para acceder al monumento. Por lo tanto, la opinión global de la oración no está clara, pero si se realiza el análisis a nivel de entidad, se identifica un aspecto positivo (la Alhambra) y otro negativo (sistema de entradas).

<sup>1</sup>En inglés: *Aspect Based Sentiment Analysis* (ABSA).

Existen diferentes métodos basados en la extracción de aspectos. Los primeros que se desarrollaron, conocidos como Métodos Basados en Frecuencias, están basados en detectar los nombres simples y compuestos más frecuentes. Por ejemplo, Hu et al. identificaron características de productos a través de algoritmos con reglas de asociación [2]. Este método fue también aplicado al dominio del turismo, donde Marrese et al. extrajeron aspectos de restaurantes y hoteles en [4]. No obstante, estos métodos no detectan aspectos con una frecuencia muy baja en el texto, los cuáles también pueden ser útiles para comprender la opinión. Por otro lado, los Métodos Basados en Sintaxis se centran en analizar las relaciones sintácticas en el texto y así extraer los aspectos [5]. Para que estos métodos tengan un alto rendimiento, se necesitan definir previamente reglas sintácticas, tantas como sean posibles, lo cuál complica considerablemente el desarrollo de estos algoritmos. Por último, durante los últimos años se ha experimentado una explosión de técnicas basadas en *deep learning*. Este tipo de métodos han conseguido mejorar el rendimiento de muchos problemas dentro de las Ciencias de la Computación, consiguiendo resultados que baten a la mayoría de metodologías pasadas. AONA es un ejemplo de cómo estos algoritmos han mejorado los resultados de ciertas tareas, el cual explicaremos en la siguiente sección.

### II-B. Deep Learning (DL)

Durante los últimos años, el DL ha revolucionado gran parte de la comunidad científica. Este tipo de estructuras algorítmicas proporciona la versatilidad del aprendizaje supervisado y sin necesitar una selección previa de características para optimizar el rendimiento final. Los modelos de *deep learning* son clasificadores no lineales que pueden ajustarse a los datos de una manera más precisa. Durante la última década, este tipo de métodos han mejorado la mayoría de *baselines* de problemas del Procesamiento del Lenguaje Natural (PLN). Por ejemplo, Collobert et al. presentaron el primer estudio que introdujo el uso de Redes Neuronales Convolucionales (CNN) en tareas de PLN [6]. Poria et al. presentaron un enfoque de AONA basado en el aprendizaje profundo, que se basa en dos capas de CNN combinadas con un conjunto de patrones lingüísticos [7]. En este trabajo, se utilizará este sistema para extraer los aspectos debido al buen rendimiento que presenta en el estudio.

### II-C. Reglas Descriptivas (RD)

El aprendizaje supervisado comprende todos aquellos métodos que aprenden una función que asigna instancias a una clase previamente etiquetada. Se utilizan cuando el objetivo es predecir la clase de nuevas instancias. En cambio, el aprendizaje no supervisado son todos aquellos métodos que infieren estructuras ocultas a partir de datos no etiquetados. En este caso, se conciben como técnicas de descriptivas de datos y analizan su estructura inherente.

Una de las técnicas más populares de aprendizaje no supervisado son las RD. Se definen como el conjunto de técnicas que apuntan a descubrir un conocimiento descriptivo guiado

por una variable de clase supervisada. El objetivo principal de las RD es entender los patrones que se transmiten en los datos, en lugar de clasificar las instancias con respecto a una variable de clase mediante reglas. Recordamos que una regla es una expresión que relaciona un cierto atributo (consecuente) con un conjunto de características (antecedente). Una de las técnicas más conocidas de RD es el *Subgroup Discover* (SD). SD es una técnica de minería de datos no supervisada que describe una conjunción de características que son propia de una clase, dónde el antecedente es el conjunto característico de valores propios de la clase.

$$R: \{\text{Subgroup Conditions}\} \longrightarrow \{\text{Class}\},$$

Esta tarea no se centra en encontrar relaciones complejas en los datos, sino que intenta cubrir las instancias a partir de los datos de una manera exhaustiva.

Existen diferentes métricas que tratan de medir la calidad y relevancia de las reglas extraídas. Las más populares son [8] y [2]:

- **Cobertura:** Número de instancias cubiertas por la regla.

$$Cov(R) = \frac{|\text{Subgroup Conditions}|}{N},$$

donde  $N$  es el total de instancias del dataset.

- **Soporte:** Número de instancias en el dataset que cumplen las condiciones del antecedente (*Subgroup Conditions*) y el valor de la clase (*Class*).

$$Sup(R) = \frac{|\text{Subgroup Conditions} \cap \text{Class}|}{N}.$$

- **Confianza:** Mide el grado de cobertura de una regla en relación al conjunto de ejemplos que satisfacen el antecedente.

$$Conf(R) = \frac{|\text{Subgroup Conditions} \cap \text{Class}|}{|\text{Subgroup Conditions}|}.$$

### III. UNA NUEVA METODOLOGÍA PARA DESCRIBIR OPINIONES

El objetivo de las tareas basadas en AONA es el de obtener información detallada sobre la opinión. Estas tareas relacionan los aspectos mencionados en un texto con una polaridad específica. Sin embargo, en este trabajo detectamos la falta de generalización de estas técnicas, pues no sirven para tener una idea global del contenido de las opiniones. Por ello, proponemos una nueva metodología que combina la extracción de aspectos con técnicas de RD para obtener una descripción global de las relaciones más relevantes entre aspectos y polaridades dentro de un corpus. En este sentido, se combinan dos poderosas herramientas: una red neuronal basada en el uso de varias capas convolucionales CNN para la extracción de aspectos y un método de SD para la agregación de información, es decir, reglas que asocien un conjunto de aspectos con una cierta polaridad, en este caso, la negativa:

$$R: \{\text{aspect}_a = 1, \text{aspect}_b = 1\}$$

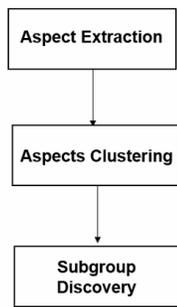


Figura 1. Flujo de la metodología propuesta.

→ {sentiment = negative}.

La metodología propuesta está basada en tres fases (ver Figura 1). La primera es extraer aspectos usando una arquitectura neuronal (Section III-A). Luego, se agrupan aspectos similares para representar el mismo concepto en una sola entidad (Sección III-B). Finalmente, se utiliza un algoritmo basado en SD para extraer la información agregada y así describir el conjunto de opiniones mediante reglas entre aspectos y polaridades (Sección III-C).

### III-A. Deep Learning para extraer aspectos

Los modelos de DL son clasificadores no lineales, lo cuáles se han convertido en el estado del arte de la gran mayoría de las tareas de PLN, debido al buen rendimiento que se ha observado. Por esta razón, en este trabajo se propone utilizar el método DL presentado en [7] para la extracción de aspectos. Este método se basa en una arquitectura convolucional, la cual utiliza como entrada las palabras que rodean a un aspecto. La arquitectura de esta red está formada por una capa de entrada, dos capas de convolución, dos capas de *pool* máximo y una capa totalmente conectada con una salida *softmax*. La salida de cada capa de convolución está calculada usando *tanh* como función de activación. Por último, se utiliza un conjunto de patrones lingüísticos que se ejecutan en la salida, lo cuales mejoran el rendimiento del método de extracción de aspectos.

### III-B. *k-nn* para agrupar aspectos

Debido a la riqueza del lenguaje natural que utilizan los humanos, cuando una persona escribe no suele utilizar la misma palabra o expresión para transmitir una misma idea. Por lo tanto, la variedad de aspectos extraídos por cualquier método de extracción de aspectos es muy amplio, y muchos de ellos pueden referirse a una misma entidad. Por ejemplo, cuando se escribe sobre la experiencia de una visita a un monumento cultural, existen muchas maneras de expresar lo mismo:

**ticket** → {onsite ticket office, senior ticket, ticket area, ticket check points, ticket office, entry ticket, service ticket, machine ticket, ticket staff, ticket price, ticket process, ...}.

La riqueza del lenguaje implica que: (1) se debe lidiar con la alta dimensionalidad de los aspectos, porque una misma entidad puede estar representada con una gran variedad de palabras idea; (2) aspectos similares semánticamente tienen representaciones diferentes. Para abordar estos problemas, en este trabajo proponemos agrupar estos aspectos en un mismo grupo o clúster, y así disminuir la dimensionalidad de aspectos extraídos.

**III-B1. De palabras a vectores:** Los *word embeddings* son representaciones de palabras en forma de vector numérico. Mikolov et al. presentaron en [9] el primer *word embedding* del estado del arte del PLN, conocido como *word2vec*. Levy et al. generalizaron este modelo teniendo en cuenta el contexto de las palabras que se representan [10]. Demostraron que los contextos sintácticos capturan otro tipo de información, por lo que su modelo recoge más similitud funcional entre las palabras representadas como vectores. Por esa razón, en este trabajo se han usado este tipo de *embeddings*<sup>2</sup>. Para esos aspectos que están compuestos por más de una palabra, su representación en *embeddings* es la media de todos los *embeddings* de las palabras que componen dicho aspecto.

**III-B2. De vectores a clústers:** El *clustering* es la tarea de agrupar un conjunto de objetos de tal manera que los que pertenecen a un mismo grupo o clúster son más similares entre ellos que entre los que pertenecen a otro clúster. En toda la literatura, existe una gran variedad de algoritmos de *clustering*. La principal diferencia entre ellos es la noción que tienen de similitud entre los objetos a la hora de formar los grupos y cómo de eficiente es la agrupación. Uno de los más populares es el *k-means*. Este es un algoritmo iterativo tiene como objetivo minimizar la varianza entre las instancias que forman un mismo grupo. Más formalmente se puede expresar como:

Dado un conjunto de elementos  $\{w_1, \dots, w_n\}$ , *k-means* agrupa las *n* observaciones en *k* clusters ( $\{C_1, \dots, C_k\}$ ), minimizando la función:

$$\arg \min_C \sum_{i=1}^k \sum_{w \in C_i} \|w - \mu_i\|^2, \quad (1)$$

donde  $\mu_i$  es la media de los puntos en  $C_i$ .

Una vez se han agrupado los aspectos similares en un mismo clúster, construimos la matriz *review-aspect* (ver Figura 1), la cuál tiene la misma estructura que una matriz *término-documento*: el elemento  $a_{ij}$  es igual a 1 si la opinión *i* contiene algún aspecto del cluster *j*, si no, es igual a 0. Por último, añadimos a esta matriz la columna de la polaridad de TripAdvisor, es decir, la puntuación que el usuario asigna a su experiencia. Como esta puntuación se basa en una escala del 1 al 5, configuramos las puntuaciones de 1 a 3 como opiniones negativas y de 4 a 5 como opiniones positivas.

<sup>2</sup><https://levyomer.wordpress.com/2014/04/25/dependency-based-word-embeddings/>

### III-C. SD para describir reglas

Los algoritmos de reglas de asociación tienen como objetivo obtener relaciones entre las variables del conjunto de datos. En este caso, las variables pueden aparecer tanto en el antecedente como en el consecuente. En los algoritmos SD, en el consecuente se asigna la variable clase, que en nuestro caso es la polaridad. Esto significa que los algoritmos de reglas de asociación se pueden adaptar perfectamente a las tareas SD.

El algoritmo Apriori [11] fue diseñado para operar en un conjunto de datos transaccional, en la que cada transacción es vista como un conjunto de ítems o características. Dado un valor de un umbral  $C$  de confianza, el algoritmo Apriori identifica todos los conjuntos de ítems que son subconjuntos de al menos  $C$  transacciones. Este algoritmo utiliza un enfoque *bottom up*, donde subconjuntos frecuentes son ampliados por un ítem a la vez (este paso se conoce como generación de candidatos). El algoritmo finaliza cuando no encuentra más ampliaciones exitosas de los conjuntos previos de ítems. Apriori-SD es la versión de este algoritmo para SD. Fue desarrollado añadiendo varias modificaciones del algoritmo Apriori C [12].

En nuestra metodología, se aplica el algoritmo Apriori-SD teniendo en cuenta:

- *items* son los aspectos,
- la *transacción* es la matriz review-aspects,
- el *antecedente* es el conjunto de aspectos que aparecen siempre juntos,
- el *consecuente* es la polaridad prefijada, negativa o positiva.

Por lo tanto, el objetivo es el de encontrar los aspectos más relevantes dentro de todas las opiniones negativas de TripAdvisor. Como medidas de evaluación de las reglas extraídas, proponemos emplear el Soporte y la Confianza.

## IV. EXPERIMENTOS

En esta sección se evalúa la eficacia de nuestra propuesta en diferentes bases de datos de opiniones. En esta sección, primero se describen los datasets empleados (Sección IV-A), luego se analizan cómo se han agrupado los aspectos (Sección IV-B), y los resultados de las reglas descriptivas (Sección IV-C).

### IV-A. El conjunto de datos

TripAdvisor es una compañía estadounidense basada en una página web de viajes que ofrece reseñas de experiencias de viajeros sobre hoteles, restaurantes y monumentos. Este sitio web ha formado la mayor comunidad de viajeros, alcanzando un total de 630 millones de visitantes únicos mensuales, y 350 millones de comentarios y opiniones que cubren más de 7.5 millones de alojamientos, restaurantes y atracciones en 49 mercados en todo el mundo<sup>3</sup>. Una de las características más relevantes de TripAdvisor es la gran cantidad de opiniones de millones de turistas cotidianos que contiene. De hecho,

<sup>3</sup>Fuente: <https://tripadvisor.mediaroom.com/uk-about-us>

Monumento	Opiniones	Opiniones con Aspectos	Aspectos
Alhambra	7.217	6.186	9.284
Mezquita	3.526	2.802	3.688
Sagrada Familia	34.558	26.386	18.553

Tabla I

NÚMERO DE OPINIONES, OPINIONES CON ASPECTOS Y ASPECTOS ÚNICOS.

Monumento	Positivo	Negativo
Alhambra	6.781 (93,96 %)	436 (6,04 %)
Mezquita	3.454 (97,96 %)	72 (2,04 %)
Sagrada Familia	32.664 (94,52 %)	1.894 (5,48 %)

Tabla II

DISTRIBUCIÓN DE LAS POLARIDAD POSITIVAS Y NEGATIVAS POR MONUMENTO.

sus opiniones han sido utilizadas como fuente de datos para muchos estudios de AO [4], [13]–[15].

Para evaluar nuestra propuesta, se propone aplicar la metodología en tres de los principales monumentos culturales a nivel nacional: la Alhambra (Granada), la Sagrada Familia (Barcelona) y la Mezquita de Córdoba (Córdoba). Para ello, se han recopilado 45,301 opiniones escritas en inglés, desde Julio de 2012 hasta Junio de 2016. La Tabla I muestra el número de revisiones por monumento, el número de revisiones con aspectos detectados, y el número de aspectos extraídos por el método descrito en la Sección III-A.

Antes de empezar con el análisis de los resultados, se propone analizar la distribución de los sentimientos en cada conjunto de datos. Se establecen las valoraciones de los usuarios de 1 a 3 como negativas, y de 4 a 5 como positivas. Como muestra en la Tabla II, las polaridades están altamente desbalanceadas. Las opiniones positivas son mucho más numerosas que las negativas, lo que significa que los usuarios de TripAdvisor tienden a evaluar positivamente su visita en estos monumentos.

### IV-B. Una idea, cien palabras

En esta sección se describen los resultados del agrupamiento de aspectos similares. Un aspecto puede estar formado por una palabra o más de una. En el segundo caso, la representación en *word embeddings* consiste en la media de todas las palabras que forman el aspecto. Además, también existen aspectos que no tienen representación en *word embeddings*, debido a faltas de ortografía, falta de espacios entre dos palabras, etc. En estos casos, no serán considerados para el agrupamiento, y formaran un clúster único. La Tabla III muestra la distribución de los aspectos con y sin representación en *word embeddings*.

Este análisis muestra la agrupación de los clústers, eligiendo  $k$  igual a 5, 20, 50, 100, 200, 500 and 1.000. Se observa que para valores muy pequeños de  $k$ , los clústers son formados

Monumento	Aspectos	Aspectos con embeddings	Aspects sin embeddings
Alhambra	9.284	5.430	3.854
Mezquita	3.688	2.291	1.397
Sagrada Familia	18.553	10.247	8.306

Tabla III

NÚMERO TOTAL DE ASPECTOS, CON Y SIN REPRESENTACIÓN EN VECTOR.



por gran número de aspectos, lo que hace que el clúster no sea una representación de una idea en común. En cambio, con  $k = 500$ , la mayoría de clústers corresponden a un mismo concepto, lo que indica que los resultados son coherentes con los de [16]. La Tabla IV muestra algunos ejemplos de clústers con  $k = 500$ .

Otra ventaja importante de la agrupación de aspectos es la reducción de la dimensionalidad. Como muestra la Tabla III, se obtienen 9.284, 3.688 y 18.553 aspectos por cada monumento, respectivamente. Después del proceso de agrupación con  $k = 500$ , estos aspectos se reducen a 4.353, 1.897 y 8.806 aspectos, respectivamente.

#### IV-C. Caracterizando las opiniones negativas de los monumentos culturales

Antes de aplicar algoritmos SD, se analizan frecuencias de los aspectos agrupados en los tres conjuntos de datos. En este análisis, la gran mayoría de los aspectos ocurren menos de 5 veces. La mayoría de estos aspectos corresponden a aquellas palabras sin representaciones vectoriales (ver Tabla III). Por otro lado, los aspectos agrupados obtienen valores con alta frecuencia, lo que tiene sentido porque representan varios aspectos, por ende se suma la frecuencia de cada aspecto que pertenece a ese clúster.

También se analizan los aspectos agrupados más frecuentes en los tres conjuntos de datos. Como se observa en la Tabla IV, en los tres monumentos las palabras más populares están relacionadas con temas arquitectónicos. Por consiguiente, se concluye que los usuarios tienden a describir el monumento mientras opinan sobre su visita en TripAdvisor.

Finalmente, se utiliza la versión del algoritmo Apriori-SD para identificar aspectos en opiniones negativa. Se fija el consecuente de las reglas con la clase *negativa* y se aplica el algoritmo SD para que descubra los aspectos en el lado del antecedente. Las Tablas V, VI y VII presentan las reglas más relevantes de las opiniones negativas de la Alhambra, Mezquita y Sagrada Familia, respectivamente. Se obtienen valores muy bajos tanto para las medidas de soporte y confianza. Los valores de soporte bajos se deben a la escasez de aspectos en todo el dataset. En cambio, los valores bajos de confianza se deben a la poca frecuencia de los aspectos respecto al conjunto total de opiniones.

Analizando el contenido de las reglas, se detectan algunos patrones interesantes en los datos. En las opiniones de la Alhambra, los clústers relacionados con *staff* (personal), *tickets* (tiquets) y *queue* (cola) son los más relevantes. De hecho, el clúster que representa todo lo relacionado con el personal es el que mayor confianza obtiene (0,3), lo que implica que es una característica muy distintiva de esta clase. En ese caso, se concluye que los usuarios de TripAdvisor que han visitado la Alhambra suelen quejar de ese aspecto. El mismo hecho se observa analizando las opiniones de la Sagrada Familia con el aspecto *queue*, a pesar que su confianza es relativamente más baja (0,06). También se observa que existen otro tipo de reglas descriptivas relacionadas con las características del monumento en sí: {*gardens*, *architecture*,

*building*, *church*, ...}. Esto es debido a que los usuarios de TripAdvisor suelen escribir información objetiva en sus opiniones, es decir, realizan descripciones arquitectónicas del monumento.

## V. CONCLUSIONES

Este trabajo presenta una metodología novedosa y eficaz para describir un conjunto de opiniones sobre alguna entidad según los aspectos nombrados. Los algoritmos de AONA extraen información muy detallada de opiniones a través de aspectos, pero no proporcionan una visión general de lo que contiene el texto. En consecuencia, se propuso combinar métodos de extracción de aspectos con técnicas de reglas, para así representar el contenido de un texto. Esta metodología se ha basado en tres fases: (1) Extracción de Aspectos, (2) Agrupamiento de Aspectos y (3) Reglas Descriptivas. Luego, esta metodología se ha aplicado sobre el conjunto de opiniones negativas de tres monumentos culturales, ya que aportan la información más valiosa para mejorar la experiencia del visitante a estos monumentos.

Los resultados muestran que la metodología propuesta es eficaz para resumir un conjunto de opiniones según sus aspectos. La principal ventaja es que ofrece una representación directa del contenido del texto. Se pudo describir una gran cantidad de reseñas culturales a través de aspectos y reglas descriptivas, lo que refuerza la comprensión de las opiniones. Por ejemplo, los visitantes de la Alhambra suelen quejarse del personal, del sistema de tickets y de las largas colas de espera. También se detectó que los usuarios tienden a describir los elementos del monumento visitado, lo que se considera como información objetiva. Este hecho es muy interesante porque no se observa cuando se analizan opiniones de restaurantes u hoteles. Sin embargo, se detectó que las métricas de las reglas son muy bajas, debido a dos razones: (1) el bajo porcentaje de opiniones negativas y (2) la poca frecuencia de los aspectos. También se detecta que en algunos casos, usar la polaridad de la opinión para todos los aspectos que aparecen en ella puede llevar a una mala interpretación del contenido.

Hay varias direcciones a seguir, guiadas por los resultados obtenidos. La primera está por la baja confianza de las reglas. Se propone aplicar la misma metodología pero extrayendo la polaridad del aspecto en concreto. Otra línea futura sería extender esta metodología a diferentes contextos como: restaurantes, hoteles o crítica de productos.

## AGRADECIMIENTOS

Este trabajo ha sido desarrollado gracias al proyecto TIN2017-89517-P del Gobierno de España. Eugenio Martínez-Cámara contó con el apoyo del Programa Juan de la Cierva Formación (FJCI-2016-28353).

## REFERENCIAS

- [1] B. Liu, *Sentiment analysis: Mining opinions, sentiments, and emotions*. Cambridge University Press, 2015.
- [2] M. Hu and B. Liu, "Mining and summarizing customer reviews," in *Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining*. ACM, 2004, pp. 168–177.

Monumento	Etiqueta del cluster	Contenido del Cluster
Alhambra	FAA	alhambra staff, member of staff, staff member, local staff, ticket staff, entry staff, palace staff, male staff, staffs
Alhambra	BAG	ticket price, ticket collectors, ticket seller, ticket prices, price child ticket, ticket buying, ticket printer, ticket stock
Alhambra	DBI	garden benches, architecture garden complexes, garden areas, garden tiles, manicured garden, botanical garden, garden mazes
Mezquita	B	ceilings, quoined ceilings, domed ceilings, pews, altars ceilings, mosques ceilings
Mezquita	DIE	guard, security guard, security guard berating
Mezquita	BFH	audio tour, audio, audio program, audio rental, multilingual audio, audio devices
Sagrada Familia	BAH	entrance map, gain entrance, entrance slot, entrance queues
Sagrada Familia	BCI	crowd waiting, waits, waiting costs, lines waiting, waiting queue, waiting times, waiting line
Sagrada Familia	DEB	shop, souvenir shop, merch shop, bookshop, adjoint shop

Tabla IV

EJEMPLO DE ASPECTOS AGRUPADOS EN UN MISMO CLUSTER.

Cluster Content	Rule	Cover.	Support	Conf.
staff	{ BBA = 1 } $\rightarrow$ { sentiment = negative }	0,02	< 0,01	0,30
tickets	{ DJG = 1 } $\rightarrow$ { sentiment = negative }	0,05	< 0,01	0,12
queue	{ BH = 1 } $\rightarrow$ { sentiment = negative }	0,05	< 0,01	0,13
alhambra	{ CAF = 1 } $\rightarrow$ { sentiment = negative }	0,27	0,02	0,07
gardens	{ CFE = 1 } $\rightarrow$ { sentiment = negative }	0,17	< 0,01	0,04

Tabla V

MOST RELEVANT RULES OF THE ALHAMBRA MONUMENT.

Cluster Content	Rule	Cover.	Support	Conf.
mosque	{ EHE = 1 } $\rightarrow$ { sentiment = negative }	0,18	< 0,01	0,02
architecture	{ EHF = 1 } $\rightarrow$ { sentiment = negative }	0,16	< 0,01	0,02
place	{ BDE = 1 } $\rightarrow$ { sentiment = negative }	0,06	< 0,01	0,02
arches	{ DJD = 1 } $\rightarrow$ { sentiment = negative }	0,05	< 0,01	0,02
building	{ DDB = 1 } $\rightarrow$ { sentiment = negative }	0,09	< 0,01	< 0,01

Tabla VI

MOST RELEVANT RULES OF THE MEZQUITA MONUMENT.

Cluster Content	Rule	Cover.	Support	Conf.
queue	{ ECA = 1 } $\rightarrow$ { sentiment = negative }	0,05	< 0,01	0,06
view	{ EJB = 1 } $\rightarrow$ { sentiment = negative }	0,06	< 0,01	0,06
construction	{ BGA = 1 } $\rightarrow$ { sentiment = negative }	0,08	< 0,01	0,05
church	{ CBG = 1 } $\rightarrow$ { sentiment = negative }	0,09	< 0,01	0,05
building	{ GB = 1 } $\rightarrow$ { sentiment = negative }	0,08	< 0,01	0,05

Tabla VII

MOST RELEVANT RULES OF THE SAGRADA FAMILIA MONUMENT.

- [3] K. Schouten and F. Frasincar, "Survey on aspect-level sentiment analysis," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 3, pp. 813–830, 2016.
- [4] E. Marrese-Taylor, J. D. Velásquez, F. Bravo-Marquez, and Y. Matsuo, "Identifying customer preferences about tourism products using an aspect-based opinion mining approach," *Procedia Computer Science*, vol. 22, pp. 182–191, 2013.
- [5] Y. Zhao, B. Qin, S. Hu, and T. Liu, "Generalizing syntactic structures for product attribute candidate extraction," in *Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics*. Association for Computational Linguistics, 2010, pp. 377–380.
- [6] R. Collobert, J. Weston, L. Bottou, M. Karlen, K. Kavukcuoglu, and P. Kuska, "Natural language processing (almost) from scratch," *Journal of Machine Learning Research*, vol. 12, no. Aug, pp. 2493–2537, 2011.
- [7] S. Poria, E. Cambria, and A. Gelbukh, "Aspect extraction for opinion mining with a deep convolutional neural network," *Knowledge-Based Systems*, vol. 108, pp. 42–49, 2016.
- [8] N. Lavrač, B. Kavšek, P. Flach, and L. Todorovski, "Subgroup discovery with cn2-sd," *Journal of Machine Learning Research*, vol. 5, no. Feb, pp. 153–188, 2004.
- [9] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient estimation of word representations in vector space," *arXiv preprint arXiv:1301.3781*, 2013.
- [10] O. Levy and Y. Goldberg, "Dependency-based word embeddings," in *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*, vol. 2, 2014, pp. 302–308.
- [11] R. Agrawal, H. Mannila, R. Srikant, H. Toivonen, A. I. Verkamo *et al.*, "Fast discovery of association rules," *Advances in knowledge discovery and data mining*, vol. 12, no. 1, pp. 307–328, 1996.
- [12] V. Jovanoski and N. Lavrač, "Classification rule learning with apriori-c," in *Portuguese Conference on Artificial Intelligence*. Springer, 2001, pp. 44–51.
- [13] A. Valdivia, M. V. Luzón, and F. Herrera, "Sentiment analysis in tripadvisor," *IEEE Intelligent Systems*, vol. 32, no. 4, pp. 72–77, 2017.
- [14] B. Lu, M. Ott, C. Cardie, and B. K. Tsou, "Multi-aspect sentiment analysis with topic models," in *Data Mining Workshops (ICDMW), 2011 IEEE 11th International Conference on*. IEEE, 2011, pp. 81–88.
- [15] W. Kasper and M. Vela, "Sentiment analysis for hotel reviews," in *Computational linguistics-applications conference*, vol. 231527, 2011, pp. 45–52.
- [16] X. Zhang and Q. Yu, "Hotel reviews sentiment analysis based on word vector clustering," in *Computational Intelligence and Applications (ICCIA), 2017 2nd IEEE International Conference on*. IEEE, 2017, pp. 260–264.



# Minería de Opinión no supervisada en Twitter

J. Ángel Díaz-García  
Dpto. Ciencias de la Computación e I.A.  
Universidad de Granada

M. Dolores Ruiz  
Dpto. Ingeniería Informática  
Universidad de Cádiz

Maria J. Martín-Bautista  
Dpto. Ciencias de la Computación e I.A.  
Universidad de Granada

**Resumen**—La minería de opiniones ha sido ampliamente estudiada en la última década dado su gran interés en el ámbito de investigación e innumerables aplicaciones al mundo real. En este trabajo proponemos un sistema que combina reglas de asociación, generalización de reglas y análisis de sentimientos para catalogar y descubrir tendencias de opinión en la red social Twitter. A diferencia de lo extendido, se usa el análisis de sentimientos para favorecer la generalización de las reglas de asociación. Para ello, primeramente mediante minería de textos se resume un conjunto inicial de 1.7 millones de tuits captados de manera no dirigida en un conjunto de entrada para los algoritmos de reglas y análisis de sentimientos de 140718 tuits. Sobre este último conjunto se obtienen sets de reglas, estándar y generalizadas, fácilmente interpretables sobre personajes que el propio sistema revelará como interesantes.

**Index Terms**—Minería de opiniones, reglas de asociación, análisis de sentimientos, análisis de tendencias, aprendizaje no supervisado

## I. INTRODUCCIÓN

Las técnicas de minería de datos están presentes en casi todas las vertientes de estudio y desarrollo con las que los seres humanos actualmente trabajan. Hay ciertos problemas en los que estas técnicas destacan notablemente influenciados por los nuevos paradigmas económicos y sociales, donde las redes sociales han tomado un papel relevante. Es en este último punto de las redes sociales donde surge lo que conocemos como análisis de tendencias o minería de opiniones en la que se utilizan las técnicas de minería de datos para el análisis de opiniones. Objeto de estudio en el que se trata de comprender o analizar comportamientos, actividades y opiniones, por ejemplo, de consumidores de cierto producto o usuarios de cierta red social.

En este trabajo, se propone un novedoso enfoque no supervisado para el problema del análisis de tendencias y la minería de opiniones cuya base nace de la unión de dos técnicas bien diferenciadas dentro del ámbito de la minería de datos, las reglas de asociación y la minería de opiniones o análisis de sentimientos, aunque diferenciando la supervisada y no supervisada. Estas técnicas por separado, han sido ampliamente estudiadas en la literatura, donde se ha constatado la potencia de las reglas de asociación para resumir y descubrir conocimiento de un gran conjunto de datos, así como la gran utilidad del análisis de sentimientos para la realización de un análisis subjetivo de los problemas o dominios donde se aplican estas técnicas. El presente proyecto, propone por tanto combinar las tres vertientes utilizando el análisis de sentimientos para enriquecer el proceso posterior de obtención

de reglas de asociación, cuya finalidad será descubrir patrones de opinión, algo que difiere de la práctica totalidad de la literatura, donde se aplican las reglas de asociación para mejorar el paso posterior de análisis de sentimientos, polarizando entidades textuales, como por ejemplo tuits en buenos, neutros o malos sin obtención de patrones sobre aquellos factores que implicarán esos resultados, así como su interpretación.

La aportación del estudio al estado del arte en la materia de la minería de opiniones y el análisis de tendencias está por tanto en el diseño de un sistema que es capaz de trabajar con datos sin filtrado que puedan ser obtenidos de Twitter, por ejemplo de un país o lengua en concreto durante un período temporal que podrá variar. Sobre estos datos, el sistema será capaz de resumir cientos de miles de tuits, en un conjunto de reglas fácilmente interpretable sobre aquella temática o personaje que al analista interese en un determinado momento. Posteriormente se podrá generalizar y visualizar estas reglas en función de los sentimientos generados, de manera que pasaremos de un conjunto de datos desestructurado a conjuntos muy reducidos de reglas que representarán los sentimientos y las tendencias, con las que podremos categorizar las opiniones sobre personajes que el sistema obtendrá de manera no dirigida.

La metodología seguida por el sistema para conseguir este objetivo es la que podemos ver en la figura 1. Partiendo de un gran conjunto de tuits, el sistema propuesto limpia en primera instancia los datos para posteriormente realizar una selección de muestras basada en la localización de personas relevantes, tras esto el sistema polariza en paralelo los términos de los tuits y obtiene reglas de asociación sobre los mismos de manera que puede combinar la polarización de sentimientos y las reglas en un enfoque jerárquico, ofreciendo en la salida, para un mismo personaje, una nube de términos con los patrones y tendencias de opinión y un set de reglas generalizadas que nos ofrecen un nivel más de obtención de información sobre esas tendencias de opinión.

Para validar el buen funcionamiento del sistema propuesto, se han escogido dos conocidos políticos de EEUU, Donald Trump y Hillary Clinton. El motivo de escoger estos personajes, entre todos los que el sistema descubrió como relevantes en la red social Twitter, es que podemos validar acorde a los actos acaecidos en el último año las opiniones, reglas y reglas basadas en sentimientos que el modelo sea capaz de minar sobre los mismos. Cabe destacar, que podríamos haber escogido cualquier otro personaje y el sistema habría funcionado también correctamente.

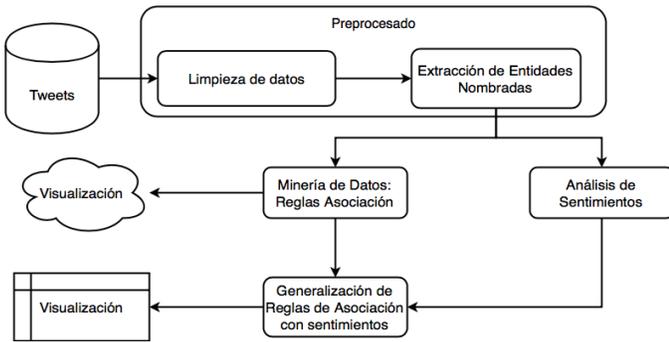


Figura 1. Flujo de la metodología.

## II. TRABAJOS RELACIONADOS

En esta sección, se estudian los trabajos relacionados con el presente estudio en función de las técnicas que se usan.

### *Reglas de asociación y minería de redes sociales.*

Uno de los principales trabajos que encontramos en el campo de las reglas de asociación es el propuesto en el 2000 por Silverstein et al. [1], donde se usan técnicas de reglas de asociación para el conocido problema de las cestas de la compra, que relaciona la compra de un determinado producto con la posibilidad de comprar otro distinto. Posteriormente, el campo ha sido ampliamente estudiado con artículos de gran interés aunque no será hasta 2010 cuando aparezca uno de los principales artículos que relacione el uso de reglas de asociación de causalidad en medios sociales. El artículo en cuestión, es propuesto por Oktay et al. [2], y en él, se estudia la relación entre la aparición de ciertos términos en preguntas de la web *Stack Overflow*, con la aparición de ciertos términos en las respuestas a estas preguntas, lo cual podría relacionarse con nuestro estudio, en el que tratamos de obtener e interpretar a relación de unos términos con otros, aunque las técnicas y el dominio difieren por completo.

Si nos centramos en nuestro dominio, Twitter, es a raíz de la publicación del trabajo de Pak and Paroubek [3], donde denotan la potencia de los datos obtenidos de Twitter para la minería de opiniones, cuando comienzan a aparecer multitud de estudios que se centran en esta red social como origen de datos sobre los cuales aplicar distintas técnicas de minería de datos, entre las que se encuentran, aunque en menor medida que otros enfoques, las reglas de asociación. En este área, encontramos trabajos como el propuesto por Cagliero y Fiori [4] o el propuesto por Erlandsson et al. [5]. En el primer estudio los autores usan reglas de asociación dinámicas, es decir, en el que las medidas de confianza y soporte cambian a lo largo del tiempo, con el fin de obtener datos sobre los hábitos y comportamientos de los usuarios en Twitter. En el segundo, se propone un análisis basado en reglas de asociación para encontrar *influencers* en Twitter, estudio que aborda el **estudio de influencias** dentro de las distintas vertientes de la minería de medios sociales. Nuestro trabajo podría verse por tanto como un híbrido entre estos dos estudios, donde se creará un modelo capaz de obtener tendencias de opinión o

relaciones acorde a personajes influyentes que a muy seguro aparecerán en el proceso. Esto se diferencia de otros trabajos como el de Meduru et al. [6] o el de Abascal-Mena et al. [7] entre otros, donde se realiza un filtrado previo de los tuits sobre los que se aplicará el procesado. En nuestro estudio, no se realiza ningún filtrado previo de los datos de Twitter.

### *Reglas de asociación y análisis de sentimientos.*

En cuanto al campo del análisis de sentimientos y las reglas de asociación, hay pocos trabajos relacionados debido al predominio de los métodos de clasificación en este área, pero, cabe mencionar el reciente interés en esta temática donde encontramos estudios como el de Hai et al. [8] donde se aplica un enfoque basado en reglas de asociación, co-ocurrencias de palabras y clustering, para obtener las características más comunes respecto a determinados grupos de palabras que puedan representar una opinión. El fin del estudio es ofrecer una vuelta de tuerca al proceso de análisis de sentimientos, que simplemente polariza una opinión, para poder refinarlo de manera que no solo se polarice ésta sino que se pueda ver acorde a qué palabras o características de opinión se ha llevado a cabo esta polarización. En este enfoque de análisis de sentimientos y aprendizaje no supervisado encontramos también el trabajo de Yuan et al. [9], en el que los autores proponen una nueva medida para la discriminación de términos frecuentes sin orientación aparente de las opiniones, lo que favorece el proceso de análisis de sentimientos posterior. El nexo de unión de estos estudios a grandes rasgos es el uso de las reglas de asociación e itemsets frecuentes para mejorar el proceso de análisis de sentimientos, esto difiere de nuestro estudio en que una vez minadas e interpretadas las reglas, se aplicará un enfoque jerárquico de las mismas basado en sentimientos, o lo que es lo mismo, usaremos el análisis de sentimientos para mejorar la interpretación de las reglas de asociación.

### *Reglas de asociación generalizadas*

Las aproximaciones jerárquicas al proceso de minado de reglas de asociación, están siendo estudiadas últimamente, debido en gran medida a la necesidad de condensar la información que estas representan de cara por ejemplo a mejorar los procesos de visualización. Un reciente ejemplo de este uso, es propuesto por Hahsler y Karpienko [10], donde se propone una visualización basada en matrices que hace uso de una simplificación jerárquica de los ítems que aparecen en las reglas de asociación. En el presente estudio, también se usa el enfoque jerárquico para simplificar las reglas, pero en lugar de hacer esto por categorías de ítems, lo haremos por sentimientos. Es en este punto, donde encontramos uno de los trabajos más íntimamente ligados al presente estudio, donde, como hemos introducido anteriormente, se usa el análisis de sentimientos para mejorar la información aportada por las reglas de asociación. Este trabajo realizado por Dehkharghani et al. [11], propone el uso de reglas de asociación para relacionar la co-ocurrencia de términos en tuits, a los que



posteriormente se clasifica en función de los sentimientos de estos términos que forman las reglas obtenidas.

Nuestro estudio, está ligado al anterior trabajo en la interpretación de correlación que hacemos de la co-ocurrencia de términos en un determinado tuit y en el uso de análisis de sentimientos para interpretar desde un enfoque subjetivo las reglas de asociación obtenidas. Nuestra propuesta se diferencia de la anterior en que realiza el análisis sin filtrar los datos de entrada, las palabras y términos son polarizados antes de la obtención de las reglas en un enfoque jerárquico basado en sentimientos tras lo que conseguimos un resumen de las reglas pudiendo, además de obtener opiniones y tendencias, categorizar los sentimientos suscitados por un personaje (también podría ser una marca, un producto o incluso un lugar) en un conjunto de tuits recopilados durante un período de tiempo.

### III. METODOLOGÍA PROPUESTA

En esta sección estudiaremos la metodología propuesta.

#### III-A. Preprocesado

Atendiendo a la naturaleza y cantidad de los datos con los que vamos a trabajar donde prácticamente cada uno de los de tuits contiene algún elemento que hace que sea totalmente distinto de los demás, se hace estrictamente necesaria una etapa previa de preprocesado de datos. Las técnicas usadas han sido las siguientes:

1. Eliminación de palabras vacías en inglés. A estas se le ha añadido la palabra *via*, que podemos considerar vacía en el ámbito que nos incumbe.
2. Eliminación de enlaces, eliminación de signos de puntuación, caracteres no alfanuméricos y valores perdidos (tuits vacíos).
3. Términos poco comunes. Se eliminan las palabras cuya frecuencia de aparición sea inferior a 30 ocurrencias, además de aquellas palabras que a pesar de tener más de 30 ocurrencias, tienen una longitud mayor de 13 letras. Esto último indicará que provienen de hashtags o unión de palabras que no tienen significado real o importancia en nuestro proceso.
4. Extracción de Entidades Nombradas: Se ha realizado un proceso de selección de instancias en la que mantendremos solo aquellas tuits que hablen de personas. Esto se ha realizado usando la técnica de *Name Entity Recognition* [12], de ahora en adelante NER, propuesta por la Universidad de Stanford y que se incluye en el *coreNLP* propuesto por Manning et al. [13] en la misma universidad. Tras la ejecución del proceso NER, obtenemos resultados bastante aceptables donde se localizan 140.718 tuits que hacen referencia a personas. Sobre este conjunto de tuits, vuelven a aplicarse las técnicas anteriores de preprocesado para refinar el proceso.
5. Paso a minúsculas: Se pasa todo el contenido a letras minúsculas para evitar discordancias. Pese a que el paso a minúsculas es uno de los principales pasos en minería de textos, en nuestro caso se aplica tras el proceso de

NER, ya que el uso de mayúsculas en los nombres propios facilita y mejora los resultados del proceso.

6. 2-gramas: Cabe esperar la posibilidad de obtener nombres compuestos por dos términos cuyo análisis en conjunto sea mucho más interesante y evite la aparición de reglas de asociación redundantes. La idea es relacionar o fusionar términos como **donald** seguido de **trump** en una sola palabra del tipo **donald-trump**. Para evitar trabajo innecesario, utilizamos un estudio que nos permita discernir si esta premisa de nombres compuestos es acertada y si sus frecuencias son tales como para ser útil esta unión. Mediante un estudio de los bigramas más comunes, damos por cierta la premisa de que hay ciertas palabras que cuya unión evitará redundancia en las reglas. Tras identificar estos términos se realiza mediante un proceso iterativo la unión de los mismos mediante un guión. Por otro lado con el análisis de comenzamos a obtener información sobre el dominio de los datos y las conversaciones en la red social que nos permitirán guiar los procesos de obtención de información posteriores.
7. Por último transformaremos los tuits en transacciones, donde cada palabra será un ítem.

Hemos obviado el proceso de *steaming* debido a que se podría perder interpretabilidad de cara a los procesos posteriores.

#### III-B. Obtención de reglas de asociación

La etapa de minería de datos ha sido llevada a cabo usando reglas de asociación mediante el algoritmo Apriori [14] sobre el que hemos aplicado valores de soporte de 0.001 y 0.0001 junto con un valor de confianza de 0.7. De esta manera obtendremos un número considerable de reglas pero cohesionadas y fuertes.

#### III-C. Polarización de términos basada en sentimientos

La motivación en este estudio para realizar análisis de sentimientos es el tener la posibilidad de polarizar las reglas de asociación que hemos obtenido en la anterior etapa de la metodología en función de los términos que aparezcan en el antecedente o consecuente de las mismas. Se ha propuesto un proceso iterativo en el que se recorre cada uno de los tuits obteniendo el sentimiento asociado a cada palabra en ese tuit, para esto usamos el paquete *syuzhet* [16] el cual hace uso del diccionario de sentimientos de mismo nombre creado por el laboratorio de literatura de Nebraska y que tiene en cuenta las 8 emociones básicas más extendidas propuestas por el psicólogo Plutchik [17]. Haciendo esto se genera una estructura de datos, en la que para cada palabra se obtiene cuantas ocurrencias tiene para cada sentimiento. Algunas de estas palabras y su sentimiento pueden verse en la figura 2.

#### III-D. Generalización de reglas basada en sentimientos

El último paso de la metodología pasa por combinar la etapa vista en el punto III-B de obtención de reglas y el punto III-C de polarización por sentimientos de los términos. Una de las diferencias más radicales del estudio frente a





Cuadro III  
REGLAS POR SENTIMIENTOS SOBRE DONALD TRUMP

Antecedente	Consecuente	Sop	Conf	Lift
{trust}	=>{donald-trump}	0.94592745	1	1
{anticipation}	=>{donald-trump}	0.59411362	1	1
{surprise}	=>{donald-trump}	0.42505133	1	1
{anger}	=>{donald-trump}	0.34565366	1	1
{fear}	=>{donald-trump}	0.29500342	1	1
{joy}	=>{donald-trump}	0.22655715	1	1
{disgust}	=>{donald-trump}	0.11293634	1	1
{sadness}	=>{donald-trump}	0.07460643	1	1

Cuadro IV  
REGLAS POR SENTIMIENTOS SOBRE HILLARY CLINTON

Antecedente	Consecuente	Sop	Conf	Lift
{trust}	=>{hillary-clinton}	0.93968872	1	1
{anger}	=>{hillary-clinton}	0.49221790	1	1
{anticipation}	=>{hillary-clinton}	0.48638132	1	1
{fear}	=>{hillary-clinton}	0.29961089	1	1
{surprise}	=>{hillary-clinton}	0.20038911	1	1
{joy}	=>{hillary-clinton}	0.14591440	1	1
{sadness}	=>{hillary-clinton}	0.07976654	1	1
{disgust}	=>{hillary-clinton}	0.07782101	1	1

Viendo la reglas se obtiene un ranking de los sentimientos que identifican a cada una de las personas estudiadas. Lo primero que sale a la vista y que podríamos concluir es que en Twitter se han emitido más tuits de apoyo y respaldo contra ambos candidatos que de otro tipo de sentimiento. Una interpretación muy interesante es la que podemos hacer del sentimiento *anger*, donde vemos cómo el 50% de los tuits que hablan de Hillary Clinton, tienen a su vez relacionados este sentimiento, por contra, Trump, tiene un 20% menos de este sentimiento, por lo que parece que la sociedad americana, a pesar de lo que parecía en Europa, estaba más en contra de Hillary Clinton que de Trump. Esto posteriormente se vería confirmado al vencer el republicano.

## V. CONCLUSIÓN Y TRABAJO FUTURO

Se ha desarrollado un modelo que es capaz de obtener patrones de comportamiento en la red social Twitter que podrían ser catalogados como tendencia y que llevados a un enfoque basado en *data streaming* podría ser incluso utilizado para categorizar las opiniones y sentimientos mayoritarios de un determinado lugar sobre un personaje en tiempo real. Se ha constatado la potencia de los métodos no dirigidos y su fácil interpretabilidad, muy cercana al lenguaje natural, en problemas similares pese a la actual hegemonía de los métodos dirigidos. Un resultado similar al obtenido con las reglas de asociación podría obtenerse mediante un estudio de frecuencias, pero estos serían computacionalmente costosos de obtener para la cantidad de datos barajada, eliminarían en cierta medida el componente no dirigido que ofrecen las reglas, al tener que decidir sobre qué palabras obtener las relaciones con otras palabras, y por último ofrecerían métricas distintas de las que pueden obtenerse de algoritmos como Apriori. De igual modo resulta interesante una comparativa entre ambos resultados y se deja la misma como trabajo futuro

que complementará al actual. Por último es necesario destacar la infinidad de temas distintos que pueden ser tratados en Twitter, haciendo que los dataset obtenidos de este sean muy interesantes y ruidosos a la par.

## AGRADECIMIENTOS

La investigación de este trabajo ha sido parcialmente apoyada por el Ministerio de Economía y Competitividad del Gobierno de España bajo el proyecto TIN2015-64776-C3-1-R.

## REFERENCIAS

- [1] C. Silverstein, S. Brin, R. Motwani, J. Ullman. Scalable techniques for mining causal structures. *Data Mining and Knowledge Discovery*, 4 (2-3) (2000), pp. 163-192
- [2] H. Oktay, B.J. Taylor, D.D. Jensen Causal discovery in social media using quasi-experimental designs. Proceedings of the first workshop on social media analytics, ACM (2010), pp. 1-9
- [3] Pak, A., & Parubek. (2010). Twitter as a corpus for sentiment analysis and opinion mining. In *LREC*
- [4] L. Cagliero and A. Fiori. Analyzing Twitter User Behaviors and Topic Trends by Exploiting Dynamic Rules. *Behavior Computing: Modeling, Analysis, Mining and Decision*. Springer, 2012 pp. 267-287.
- [5] F Erlandsson, P Bródka, A Borg, H Johnson: Finding Influential Users in Social Media Using Association Rule Learning. *Entropy* 18: 164 (2016).
- [6] Meduru, M., Mahimkar, A., Subramanian, K., Y. Padiya, P., & N. Gunjgur, P. (2017). Opinion Mining Using Twitter Feeds for Political Analysis. *International Journal Of Computer (IJC)*, 25(1), 116-123.
- [7] Abascal-Mena R., López-Ornelas E., Zepeda-Hernández J.S. User Generated Content: An Analysis of User Behavior by Mining Political Tweets. In: Ozok A.A., Zaphiris P. *Online Communities and Social Computing, OCSC 2013*. Lecture Notes in Computer Science, vol 8029. Springer, Berlin, Heidelberg
- [8] Hai Z., Chang K., Kim J. (2011) Implicit Feature Identification via Co-occurrence Association Rule Mining. In: Gelbukh A.F. (eds) *Computational Linguistics and Intelligent Text Processing, CICLing 2011*. Lecture Notes in Computer Science, vol 6608. Springer, Berlin, Heidelberg
- [9] Yuan M., Ouyang Y., Xiong Z., Sheng H. (2013) Sentiment Classification of Web Review Using Association Rules. In: Ozok A.A., Zaphiris P. (eds) *Online Communities and Social Computing, OCSC 2013*. Lecture Notes in Computer Science, vol 8029. Springer, Berlin, Heidelberg
- [10] Hahsler, M., Karpienko, R. Visualizing association rules in hierarchical groups. (2017) *Journal of Business Economics*, 87, pp. 317-335.
- [11] R. Dehkharghani, H. Mercan, A. Javeed, Y. Saygin: Sentimental causal rule discovery from Twitter. *Expert Syst. Appl.* 41(10): 4950-4958 (2014).
- [12] Jenny Rose Finkel, Trond Grenager, and Christopher Manning. 2005. Incorporating Non-local Information into Information Extraction Systems by Gibbs Sampling. *Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL 2005)*, pp. 363-370.
- [13] Manning, Christopher D., Mihai Surdeanu, John Bauer, Jenny Finkel, Steven J. Bethard, and David McClosky. 2014. The Stanford CoreNLP Natural Language Processing Toolkit In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, pp. 55-60.
- [14] R. Agrawal and R. Srikant Fast algorithms for mining association rules in large databases. 1994. *Proceedings of the 20th International Conference on Very Large Data Bases, VLDB*, pp. 487-499.
- [15] B Liu, L Zhang . A survey of opinion mining and sentiment analysis. *Mining text data*, 2012. Springer.
- [16] Jockers, M. (2017). Package 'syuzhet'. URL: <https://cran.r-project.org/web/packages/syuzhet>.
- [17] Plutchik, R. (2001). The nature of emotions: Human emotions have deep evolutionary roots, a fact that may explain their complexity and provide tools for clinical practice. *American scientist*, 89(4), 344-350.
- [18] Matei Zaharia, Reynold S. Xin, Patrick Wendell, Tathagata Das, Michael Armbrust, Ankur Dave, Xiangrui Meng, Josh Rosen, Shivaram Venkataraman, Michael J. Franklin, Ali Ghodsi, Joseph Gonzalez, Scott Shenker, and Ion Stoica. 2016. Apache Spark: a unified engine for big data processing. *Commun. ACM* 59, 11 (2016), 56-65.

**V Congreso de la  
Sociedad Española para  
las Ciencias del  
Videojuego  
(V CoSECiVi)**

PEDRO ANTONIO GONZÁLEZ  
DAVID CAMACHO

**Secretaría Técnica:**

MARCO ANTONIO GÓMEZ Y ANTONIO MORA





**V Congreso de la  
Sociedad Española para  
las Ciencias del  
Videojuego  
(V CoSECiVi)**

SESIÓN 1







# Una Plataforma de Integración Continua Especializada en Desarrollo de Videojuegos

Iván Martínez-Mateu  
Research & Development  
Taiger  
Madrid, España  
ivan.martinez@taiger.com

Federico Peinado  
Ingeniería del Software e Inteligencia Artificial  
Universidad Complutense de Madrid  
Madrid, España  
email@federicopeinado.com

**Resumen**—Los estudios de desarrollo de videojuegos invierten mucho esfuerzo en mejorar la calidad de sus productos, beneficiándose significativamente de toda metodología y herramienta que les permita garantizar la integridad de sus procesos de trabajo con el menor coste posible. Desde hace años la industria del software cuenta con paradigmas y tecnologías que facilitan el trabajo a sus equipos de desarrollo, automatizando la mayoría de las tareas que anteriormente eran tediosas y originaban retrasos y errores. Este es el caso de la integración continua, una práctica de desarrollo en la que todos los miembros del equipo integran sus contribuciones como mínimo una vez al día, siendo cada integración verificada y probada exhaustivamente de forma automática para detectar lo antes posible cualquier conflicto. Tras detectar que esta práctica no ha calado lo suficiente entre los desarrolladores independientes de videojuegos, se propone cambiar la situación mediante el proyecto de construcción de una plataforma de integración continua orientada hacia el desarrollo, las pruebas y la publicación de videojuegos. Como resultado se obtiene la primera versión funcional de una herramienta basada en microservicios web que se presenta como libre, gratuita y de fácil manejo para los desarrolladores.

**Palabras clave**—Desarrollo de Videojuegos, Informática del Entretenimiento, Metodologías Ágiles, Ingeniería del Software, Tecnologías Web.

## I. INTRODUCCIÓN

En el ciclo de vida del software, todo proyecto pasa por diferentes procesos de análisis, diseño, implementación y pruebas. Lo habitual en un proyecto de alta calidad es tener que realizar miles de pruebas distintas en múltiples plataformas o configuraciones diferentes, todo ello para cada versión generada. Realizar manualmente todas estas tareas es costoso y perjudicial para la integridad y fiabilidad del proceso.

En la última década la industria del software ha promovido el uso de procedimientos y tecnologías, asociadas a las llamadas metodologías ágiles, que facilitan el trabajo a sus equipos de desarrollo, automatizando muchas tareas que antes debían realizarse a mano, originando retrasos, errores y conflictos de todo tipo.

Concretamente nos interesa el caso de la integración, la entrega y el despliegue continuo de software, un conjunto de prácticas de desarrollo en las que todos los miembros del equipo incorporan sus contribuciones al producto final como mínimo una vez al día, siendo cada integración, cada entrega y cada despliegue debidamente verificado y probado exhaustiva

y automáticamente, con el fin de detectar cualquier problema lo antes posible.

El escenario típico comienza cuando el desarrollador sube los cambios del código fuente al repositorio común. Periódicamente la plataforma de integración, entrega y despliegue continuo está analizando el repositorio para detectar si se ha producido un cambio. Por ello, en cuanto se han remitido dichos cambios (*commit*) al repositorio, la plataforma los detecta y procede a descargar la última versión de todo el código fuente del proyecto. Una vez descargado este código, la plataforma ejecuta los *scripts* de construcción de proyecto. En estos *scripts* se indica qué pasos se deben seguir para compilar y ejecutar los tests del proyecto (por ejemplo, si es necesario descargar dependencias, utilizar alguna directiva de precompilación (*flag*), etc.). El resultado de la ejecución de estos *scripts* se enviará por correo electrónico o por otro método de comunicación a los integrantes del equipo de desarrollo para informarles del estado de la construcción automática, es decir, si se ha producido un error o si por el contrario todo marcha bien.

Aunque los estudios de desarrollo de videojuegos están a la última en tecnología e invierten mucho esfuerzo en mejorar la calidad de sus productos, hemos detectado (como se detallará más adelante en la Discusión) que la práctica de la integración continua es a menudo desconocida o confundida con otras prácticas populares por los desarrolladores independientes de videojuegos.

El ámbito del desarrollo de videojuegos puede verse como un subproblema del desarrollo de *software*, aunque muy peculiar [15] [11]. Entre lo específico de los proyectos de videojuegos está la variedad de talento humano que interviene en el proceso de creación y desarrollo, personas con diferente nivel de conocimiento que a menudo no suelen estar concienciados con los procesos de integración continua. Un desconocimiento que puede suponer complicaciones ya que en un videojuego, un fallo no sólo se puede producir por un error en el código, sino también por un fichero de audio corrupto o un modelo 3D cuya calidad es excesivamente alta y provoca que el juego no gestione correctamente los recursos para representarlo visualmente por pantalla. Además, el desarrollador está llamado a optimizar recursos: el juego suele ocupar mucho espacio y consumir muchos recursos (lo

cual afecta claramente a su alojamiento y a la forma de trabajar con él) y dinámicamente, carga y descarga recursos muy pesados en tiempo real. Además de los controles de calidad y pruebas de *UX* normales, los videojuegos también requieren de *playtesting*, es decir, comprobar que son divertidos, no demasiado difíciles para superar ciertos niveles, con una dificultad ajustable gradualmente, etc. Una plataforma de integración, entrega y despliegue continuo para el desarrollo de videojuegos vendría a ser una herramienta que tratase de automatizar todas las pruebas y compilaciones que se realicen, de notificar de aquellos elementos del juego que consumen muchos recursos, etc. y, en definitiva, de lograr aumentar la calidad del producto sin incurrir en elevados costes temporales y económicos.

Consideramos importante trata de cambiar esta situación y para ello en este artículo proponemos una plataforma de integración continua especializada en el desarrollo, la prueba y la publicación de videojuegos, herramienta que es contribución principal de un Trabajo Fin de Máster de reciente aprobación [9].

#### A. Objetivos

Estos son los objetivos principales del proyecto:

- Simplificar la instalación, configuración y uso de la tecnología de integración continua para los desarrolladores de videojuegos.
- Especializar las tareas habituales del proceso de integración continua para que resulten más prácticas y conecten mejor con el flujo de desarrollo, prueba y publicación de un videojuego.
- Como consecuencia, reducir el tiempo que se tarda en tener listas nuevas versiones y mejorar la calidad de las mismas.

#### B. Estructura del artículo

El artículo presenta la siguiente estructura: tras esta primera sección de Introducción, se presenta una revisión del concepto y las herramientas de integración continua. A esta sección le sigue otra sobre la metodología utilizada, incluyendo lenguaje y tecnologías de desarrollo, y otra con los resultados obtenidos, la propia plataforma, y con la discusión sobre su enfoque y utilidad práctica. Finalmente en la sección de Conclusiones destacamos los aspectos más prometedores del proyecto y esbozamos las futuras líneas a seguir para mejorarlo.

## II. ESTADO DE LA TÉCNICA

Las ventajas de usar integración continua hoy día, una práctica originalmente propuesta en 2001 con la creación de CruiseControl [12], son claras dentro de la disciplina de la Ingeniería del Software [3]. Una de las partes importantes de la automatización de este tipo de procesos es que ofrece uniformidad, seguridad y garantía de que todas las pruebas se van a ejecutar de la misma forma. Esto se refiere tanto a la automatización de las pruebas de unidad, que se ejecutan antes de construir la versión del software, como a la etapa de pruebas funcionales.

En el caso de los videojuegos es cierto que uno de los entornos de desarrollo más populares, Unity, cuenta con un sistema para la construcción automática de versiones llamado Unity Cloud Build [18], hoy día rebautizado como Unity Teams. Esta solución es gratuita en principio pero va resultando más costosa según el tamaño del equipo y las prestaciones de hardware y software necesarias.

Desgraciadamente no todos los entornos de desarrollo tienen un servicio de automatización como este. Cuando esto ocurre, se suelen usar sistemas externos populares y versátiles como puede ser Jenkins [7] o Travis [17], para la verificación de código. Esta es probablemente la herramienta más popular para automatizar procesos de construcción en la industria de los videojuegos, se trata de una plataforma sencilla donde es fácil definir trabajos y tiene además una comunidad muy activa. Además el código se construye automáticamente en un solo paso, con lo que usuarios -expertos, eso sí- pueden construir el videojuego para varias plataformas en un sólo paso. Jenkins además ha incorporado recientemente un editor visual de pipelines, Blue Ocean, que facilita su uso por miembros del equipo que no tengan conocimientos de programación.

Existen además otros sistemas como TeamCity [8], donde los proyectos C# se integran con mayor facilidad, lo cual es interesante para el desarrollador de Unity. En cualquier caso los sistemas de integración continua que existen actualmente o son gratuitos y relativamente complejos de administrar y mantener, o son de pago, y tienen licencias costosas que a menudo son difíciles de asumir por muchos desarrolladores independientes de videojuegos.

Los sistemas de integración continua se apoyan a su vez en sistemas de control de versiones como es el caso del clásico Concurrent Versions System (CVS) [2], que mantienen un registro minucioso del trabajo realizado y permiten que varios desarrolladores colaboren a la vez sobre un mismo proyecto. Su representante actual sería Subversion (SVN) [16], un sistema centralizado de control de versiones de código abierto, cuyo funcionamiento se asemeja al de un sistema de ficheros. Otro igual de popular es Git [5], diseñado por Linux Torvalds para proyectos con gran cantidad de código fuente. Finalmente Mercurial [10], por su parte, ofrece un diseño que proporciona una gran escalabilidad y rendimiento en la gestión de archivos tanto de texto como binarios, con capacidades avanzadas de ramificación e integración, a la par que manteniendo cierta sencillez conceptual.

## III. METODOLOGÍA Y DESARROLLO

Para el diseño de la plataforma propuesta se han tomado referencias de las características más destacadas de las herramientas del estado de la técnica que aparecen en la Tabla I.

La plataforma está desarrollada utilizando Java [6] como plataforma tecnológica, lo que permite desplegarla en los sistemas operativos más utilizados, y utiliza además el almacén Spring Boot [13] para ofrecer una arquitectura basada en microservicios. De esta forma, está asegurado que la plataforma pueda escalar horizontalmente de forma sencilla de acuerdo a la carga de trabajo y que tenga una alta disponibilidad.



	Jenkins	Circle	Travis	Unity Cloud	TFS	GameCraft
Soporta macOS	✓	✓	✓	✓		✓
Soporta GNU/Linux	✓	✓	✓	✓		✓
Soporta Windows	✓			✓	✓	✓
Gratuito	✓					✓
Código abierto	✓					✓
Soporte a plug-ins	✓	✓	✓		✓	
Soporte a Unity				✓		✓
Soporte a Unreal						✓
Soporte a Monogame						✓
Soporte a Libgdx						✓
Soporte a otros motores	✓	✓	✓		✓	✓
QA	✓	✓	✓		✓	

Tabla I

COMPARACIÓN DE LAS PLATAFORMAS DE INTEGRACIÓN CONTINUA ANALIZADAS

También se configura así como un sistema abierto que permite incluir funcionalidades desarrolladas por terceros.

La plataforma recibe el nombre de GameCraft y su arquitectura se representa de forma esquemática en la Fig. 1. A continuación, se explica cada microservicio del sistema:

- **Registry:** Tiene tres labores principales: Es un servidor *Eureka* [4], cuyo propósito es descubrir la dirección IP de los microservicios y ubicarlos en la red y es un servidor de *Spring Cloud Config* [14], cuyo propósito es centralizar y distribuir la configuración inicial para que cada microservicio pueda funcionar correctamente.
- **Gateway:** Sirve para hacer posible el encaminamiento HTTP y el balanceo de carga entre los diferentes microservicios, mantener la calidad de servicio, ofrecer seguridad y documentación API para todos los microservicios. Al igual que el microservicio de registro, el microservicio de enrutamiento tiene un panel de administración donde además se puede acceder a las bases de datos registradas por cada microservicio y manipularlas, gestionar los usuarios registrados en la plataforma, etc. Este microservicio utiliza el armazón *Zuul Proxy* [19] para posibilitar todas las funciones anteriormente descritas.
- **Notificador de e-mail:** Se encarga de conectarse con un servidor de correo electrónico para poder enviar *e-mails* acerca del estado de ejecución de un *pipeline*.
- **Notificador de Slack:** Se encarga de conectarse con un *bot* de *Slack* para poder enviar mensajes a través de este medio acerca del estado de ejecución de un *pipeline*.
- **Administrador de pipelines:** Permite crear y almacenar

los *pipelines* del sistema, además de ejecutarlos.

- **Notificador de Telegram:** Se encarga de conectarse con un *bot* de *Telegram* para poder enviar mensajes a través de este medio acerca del estado de ejecución de un *pipeline*.
- **Notificador de IRC:** Se encarga de conectarse con un servidor de *IRC* para poder enviar mensajes acerca del estado de ejecución de un *pipeline*.
- **Notificador de Twitter:** Se encarga de conectarse con una cuenta de *Twitter* para poder publicar *tuits* acerca del estado de ejecución de un *pipeline*.
- **Administrador de motores:** Permite crear, almacenar e invocar los motores, es decir, los entornos integrados de desarrollo para cada proyecto, como por ejemplo, *Unity* o *gcc*.
- **Administrador de proyectos:** Permite crear y almacenar proyectos (es decir, los videojuegos que se quieren compilar y procesar) dentro del sistema.

El usuario accede a través de la interfaz de usuario de la plataforma, que es un microservicio más de la arquitectura. Para poder manejar los datos procedentes de otros microservicios desde la interfaz de usuario, las peticiones primero se encaminan hacia el *Gateway*, que se encarga de validar que la petición procede de un usuario autenticado, y redirige la petición al microservicio adecuado. De acuerdo con la arquitectura de microservicios, cada microservicio debe ser independiente, y por tanto, este es el motivo de que cada uno tenga bases de datos independientes. Siempre que se quiere obtener un dato, por ejemplo, de la base de datos de proyectos, hay que hacer uso de la *API Rest* diseñada en el microservicio de proyectos.

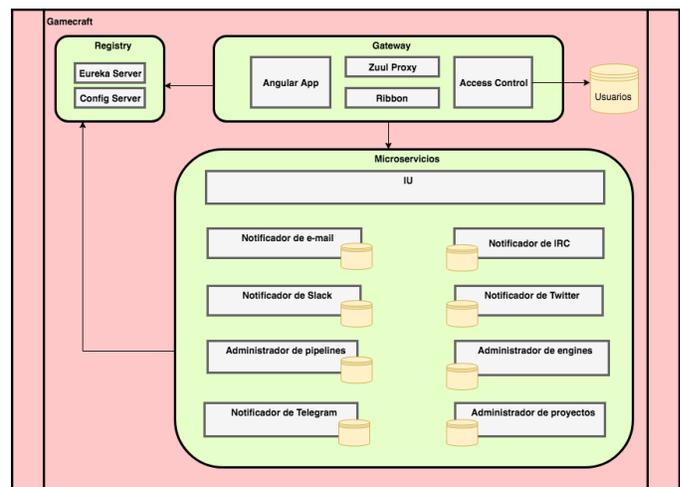


Fig. 1. Esquema de la arquitectura lógica de GameCraft.

El proceso de desarrollo seguido ha sido iterativo e incremental, para lo cual ha sido de gran ayuda la gran modularidad de la propuesta.

#### IV. RESULTADOS Y DISCUSIÓN

Como parte del proceso de diseño de la plataforma, se realizó una consulta en línea a 17 desarrolladores de videojuegos

españoles con el fin de conocer su nivel de conocimiento e interés por una práctica del desarrollo industrial de proyectos como es la integración continua. Los resultados de la encuesta<sup>1</sup> se adjuntan a continuación, agrupando todas las respuestas obtenidas en cada una de las preguntas:

• **Q1 - Tengo experiencia usando herramientas de integración continua en el trabajo.**

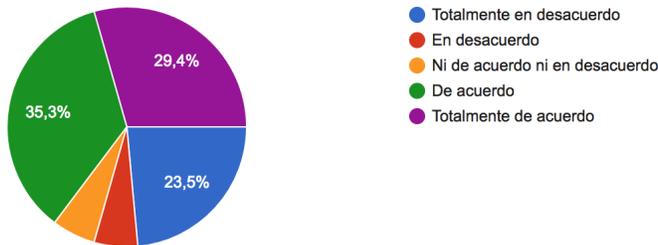


Fig. 2. Resumen de las respuestas obtenidas a la primera pregunta de la encuesta

• **Q2 - ¿Qué herramientas de integración continua has utilizado?**

- SVN, Git. (2)
- Mercurial, Git y Perforce.
- En mi trabajo en el estudio de videojuegos ninguna, en el otro trabajo me han llegado a explicar el uso de Jenkins.
- Jenkins pero solo para probar. Mi empresa no usa herramientas de este tipo por desgracia.
- TFS.
- MercuryEngine (motor propio de Mercury).
- AgileCraft, Scrum, JIRA.
- Bitbucket, con cliente TortoiseHG para mercurial y SourceTree para Git.
- SVN, Git, Perforce, Mercurial.
- Git, SVN, Mercurial.
- Jenkins, Gitlab CI.
- Perforce, tortoise svn.
- Perforce.
- Jenkins pipeline.
- Ninguna.
- AppVeyoy y TravisCI con GitHub.

• **Q3 - Considero que la integración continua es un asunto exclusivo de los programadores.**

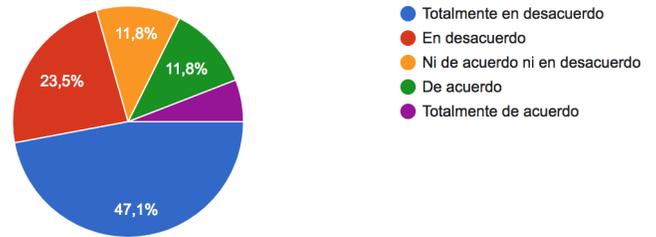


Fig. 3. Resumen de las respuestas obtenidas a la tercera pregunta de la encuesta

• **Q4 - Considero que mi empresa actual da importancia a la integración continua.**

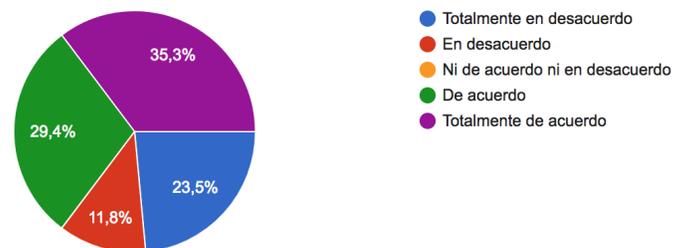


Fig. 4. Resumen de las respuestas obtenidas a la cuarta pregunta de la encuesta

• **Q5 - Considero que la integración continúa debería ser más importante en mi empresa actual.**

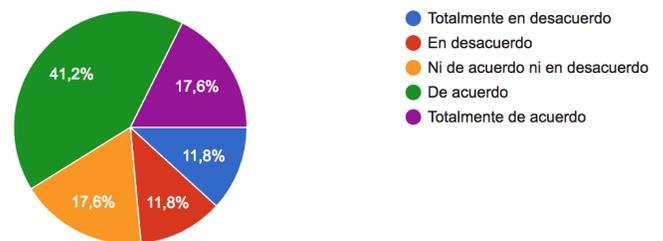


Fig. 5. Resumen de las respuestas obtenidas a la quinta pregunta de la encuesta

• **Q6 - En el uso profesional de las herramientas de integración continua, ¿cuales son los principales obstáculos y dificultades?**

- El trabajo con archivos binarios y las herramientas, a veces, poco intuitivas.
- Mentalizar a TODO el equipo de que cualquier cosa que se suba al repositorio debe ser probada, aún si no hay herramientas de integración continua. Entender bien cómo se puede aplicar la integración continua en videojuegos de cierto tamaño porque no lo veo nada claro más allá de que "compila, luego está OK" o, a lo sumo, pruebas unitarias tontorronas para métodos sueltos de cierta complejidad.

<sup>1</sup>[https://docs.google.com/forms/d/1UljfP9vSAPvScdg8iJBqTTE7OkZXv-e\\_w25z9RbhQ4U](https://docs.google.com/forms/d/1UljfP9vSAPvScdg8iJBqTTE7OkZXv-e_w25z9RbhQ4U)



- No querer aprender por parte de mis superiores.
- Se requiere de un equipo potente -y dedicado exclusivamente a esta tarea- para que las pruebas se ejecuten con la rapidez necesaria. A medida que el proyecto crece, cada ciclo requiere más tiempo. Por lo que es útil que la herramienta acepte diferentes parámetros como hacer build o re-build del proyecto, poder precompilar scripts como los .lua, seleccionar solo ciertas secciones de código para la integración continua (por ejemplo X niveles de un juego en vez de todos), etc. Por la misma causa que el punto anterior, puede llegar a ser necesario tener 2 máquinas dedicadas a integración continua, cada una encargándose de una parte diferente (o incluso tener varias integraciones continuas en cada máquina). La integración continua puede llegar a ser una responsabilidad del equipo de QA. Pero esto requiere que el responsable tenga conocimientos técnicos para interpretar los errores y aumentar la eficiencia de este proceso.
- Dificultad de Implantación, cuestionables ventajas.
- Curva de aprendizaje para los no técnicos. Problemas de *merges*.
- Integración de archivos binarios.
- La adaptación de un usuario primerizo al uso de herramientas como estas. Normalmente suelen generar problemas durante cierto tiempo. A veces pueden generar caos por no realizar correctamente el protocolo exigido.
- El aprendizaje de los novatos.
- *Merging* y *branching*.
- El uso de lenguajes *script* sin compilador causa muchas iteraciones hasta que el *script* funciona
- Entender la filosofía y aplicarlo de forma continua.
- En nuestra experiencia ha sido la instalación y configuración inicial del servidor.
- My Spanish is not good, but I can read. The main difficulties is that developers do not understand the importance of CI, and not willing to write unit tests.
- La comunicación.
- Setup para multiples plataformas "no standard".
- **Q7 - ¿Qué características y facilidades valorarías más en una hipotética herramienta de integración continua?**
  - Que sea gratis. (7 votos)
  - Que sea de código abierto. (4 votos)
  - Que se integre fácilmente con *Unity* o *Unreal*. (8 votos)
  - Que esté bien documentado. (9 votos)
  - **Que sea fácil de instalar y configurar. (13 votos)**
  - Que sea fácilmente escalable. (8 votos)
  - Que esté tanto en español como en inglés. (3 votos)
  - Que ofrezca servicios adicionales para la mejora de productividad como analizador de calidad de código. (4 votos)
  - Que su funcionalidad pueda ampliarse mediante *plug-ins*. (7 votos)
  - Otro: Multiplataforma. (1 voto)
  - Otro: Compatible con Docker. (1 voto)
- **Q8 - ¿Qué aspectos y funcionalidades valoras más en las herramientas de integración continua que ya has utilizado?**
  - Soporte para *macOS*. (7 votos)
  - Soporte para *GNU/Linux*. (4 votos)
  - **Soporte para Windows. (12 votos)**
  - Que sea gratuito. (7 votos)
  - Que sea de código abierto. (2 votos)
  - Que esté traducido en varios idiomas. (1 voto)
  - Que pueda integrarse con *plug-ins* de terceros. (3 votos)
  - Que tenga soporte nativo al motor *Unity*. (4 votos)
  - Que tenga soporte nativo al motor *Unreal*. (4 votos)

- Que tenga soporte nativo al motor *Monogame*. (0 votos)
- Que tenga soporte nativo al motor *Libgdx*. (0 votos)
- Que cuente con un buen analizador de calidad de código. (4 votos)
- Que tenga buena documentación. (5 votos)
- Que sea fácil de instalar. (10 votos)
- Que sea fácil de configurar. (13 votos)
- Otro: Que sean muy adaptables al proyecto en desarrollo. (1 voto)
- Otro: Poder excluir fácilmente archivos a sincronizar. (1 voto)
- Otro: Que sea fácil de usar. (1 voto)

En el cuestionario había preguntas relativas a la experiencia con herramientas de integración continua en su trabajo, De los 17, 11 afirmaban tener experiencia, pero de estos sólo 3 contestaban correctamente cuando se les preguntaba por las herramientas que habían utilizado. El resto sorprendentemente confundían la integración continua con el mero hecho de usar sistemas de control de versiones como SVN o Git.

Esos resultados recuerdan, salvando las distancias, a los de Angioni et al. [1], quienes al describir una metodología ágil para el desarrollo distribuido compararon similitudes, diferencias y aplicabilidad de las distintas prácticas usadas en el desarrollo de software de código abierto, descubriendo que un 72% de los desarrolladores conocían estas prácticas, pero que menos del 10% usaban algunas de las más básicas como programar en pareja o realizar iteraciones cortas.

De los 17 encuestados sólo 3 opinaban que el asunto de la integración continua es un problema exclusivo de los programadores, y 8 consideraban que su empresa debería darle más importancia a esta práctica,

Del análisis de las respuesta a la encuesta realizada se pueden extraer varias ideas:

- Algunos usuarios no saben distinguir realmente lo que es una herramienta de integración continua, poniendo herramientas y tecnologías que no son tales como Git, SVN o Bitbucket. Esto se debe a que herramientas de este tipo no se aplican en muchas organizaciones y empresas, y por tanto, los usuarios no tienen claro qué responder ya que no han conocido o no han tenido la oportunidad de utilizar estas herramientas.
- Existe una mayoría que piensa que la integración continua debería ser más importante en el lugar de trabajo. Esto permite afirmar que la gente es consciente de algunas de las ventajas que el uso de estas herramientas puede ofrecer al equipo y posiblemente no dudarían en recomendar herramientas como Jenkins o la propia GameCraft a sus superiores si eso les ayuda en el trabajo.
- La mayoría pide que una herramienta de este tipo sea fácil de instalar y configurar, lo que confirma y justifica una de las prioridades de diseño de GameCraft.
- Algunas personas encuestadas no vieron las ventajas de GameCraft frente al resto de alternativas que existen en el mercado. Si bien es cierto que se pueden utilizar herramientas como Jenkins o Travis CI para poder tratar proyectos de videojuegos, su dificultad en la instalación y configuración, el hecho de que muchas de las soluciones

existentes en el mercado son de pago y que no haya una solución desarrollada a partir de una arquitectura de microservicios, hacen que GameCraft sea una alternativa interesante frente a herramientas ya asentadas. Además, GameCraft es un proyecto gratuito y de código abierto, por lo que puede ser modificado para cualquier entorno de trabajo sin mucha complejidad.

Los sistemas gratuitos como Jenkins, que es el más conocido por los desarrolladores que sí conocen lo que es la integración continua, tienen una curva de aprendizaje y un coste de mantenimiento elevados para el administrador por la gran cantidad de opciones que existen en la plataforma. Los videojuegos tienen algunas peculiaridades, como la multidisciplinaridad de sus miembros en el equipo de desarrollo, la complejidad de los entornos de desarrollo integrados que se suelen utilizar como base, el tamaño en disco de sus proyectos y la cantidad de ficheros con información binaria y muy pesada que estos manejan. Al especializar nuestra plataforma para este dominio, se reducen significativamente todas esas opciones, quedándonos con las estrictamente necesarias para el desarrollo de videojuegos.

La plataforma GameCraft está actualmente publicada bajo licencia de código abierto<sup>2</sup>.

## V. CONCLUSIONES

Este proyecto tiene el propósito de encontrar maneras de fomentar buenas prácticas de desarrollo en las empresas de videojuegos, que les ayuden a mejorar la calidad de sus productos, aumentar la productividad y reducir el coste de sus procesos. Habiendo detectado que la integración continua es todavía una gran desconocida para muchos desarrolladores de videojuegos y que las necesidades en este ámbito no son realmente las mismas que cabría esperar de cualquier ámbito del software, se propone la creación de una plataforma de integración continua especializada para este tipo de creaciones.

Como resultado se obtiene la primera versión funcional de una herramienta basada en microservicios web que ha sido publicada libre, gratuita y que ofrece un interfaz web sencillo a sus usuarios. Con la plataforma GameCraft se pone a disposición de todos una herramienta gratuita, con una interfaz de usuario sencilla y adaptada a los procesos de desarrollo de videojuegos, escalable a cualquier tamaño de un proyecto y de código abierto, por lo que puede adaptarse a las necesidades de cualquier desarrollador.

### A. Trabajo futuro

Entre los ambiciosos objetivos que se plantean para el proyecto a medio y largo plazo están:

- Realizar pruebas con usuarios y proyectos reales, a ser posible en entornos de desarrollo de producción.
- Ampliar el enfoque e ir más allá de la integración continua, camino hacia la automatización del proceso completo, no sólo de integración, sino también de entrega y despliegue de videojuegos.

- Incorporar aprendizaje automático para aprovechar los datos de realización de trabajos y poder así anticiparse a problemas que estén próximos a ocurrir.

## AGRADECIMIENTOS

Este trabajo se apoya parcialmente en el proyecto ComunicArte: Comunicación Efectiva a través de la Realidad Virtual y las Tecnologías Educativas, financiado por las Ayudas Fundación BBVA a Equipos de Investigación Científica 2017, y el proyecto NarraKit VR: Interfaces de Comunicación Narrativa para Aplicaciones de Realidad Virtual (PR41/17-21016), financiado por las Ayudas para la Financiación de Proyectos de Investigación Santander-UCM 2017.

## REFERENCIAS

- [1] Angioni, M., Sanna, R., Soro, A. (2005). Defining a Distributed Agile Methodology for an Open Source Scenario. In Scott, M., Succi, G. (eds.): Proceedings of the First International Conference on Open Source Systems. Springer Verlag pp. 209-214.
- [2] Concurrent Versions System (2018). Concurrent Versions System. <http://www.nongnu.org/cvs/>
- [3] Duvall, P., Matyas, S. M., Glover, A. (2007). Continuous Integration: Improving Software Quality and Reducing Risk (The Addison-Wesley Signature Series). Addison-Wesley Professional.
- [4] Eureka (2018). Eureka. <https://github.com/Netflix/eureka>
- [5] Git (2018). Git. <https://git-scm.com>
- [6] Java (2018). Java. <https://www.java.com>
- [7] Jenkins (2018). Jenkins. <https://jenkins.io>
- [8] JetBrains (2018). TeamCity. <https://www.jetbrains.com/teamcity>
- [9] Martínez Mateu, I. (2018). GameCraft: Una plataforma de integración continua para videojuegos basada en microservicios. Trabajo Fin de Máster en Ingeniería Informática. Universidad Complutense de Madrid.
- [10] Mercurial (2018). Mercurial. <https://www.mercurial-scm.org>
- [11] Scacchi, W. (2018). Free and Open Source Development Practices in the Game Community.
- [12] Sharma, A. (2018). A Brief History of DevOps, Part III: Automated Testing and Continuous Integration. <https://circleci.com/blog/a-brief-history-of-devops-part-iii-automated-testing-and-continuous-integration/>
- [13] Spring Boot (2018). Spring Boot. <https://spring.io/projects/spring-boot>
- [14] Spring Cloud Config (2018). Spring Cloud Config. <https://cloud.spring.io/spring-cloud-config/>
- [15] Stacey, P., Nandhakumar J. (2004). Managing the Development Process in a Games Factory : A Temporal Perspective.
- [16] Subversion (2018). Subversion. <https://subversion.apache.org>
- [17] Travis CI (2018). Travis. <https://travis-ci.org>
- [18] Unity (2018). Unity Cloud Build. <https://unity3d.com/learn/tutorials/topics/cloud-build/>
- [19] Zuul Proxy (2018). Zuul Proxy. <https://github.com/Netflix/zuul>

<sup>2</sup><https://github.com/iMartinezMateu/gamecraft>



# Análisis y propuesta de una herramienta basada en gamificación para la educación en valores dentro del deporte

Raquel Menéndez-Ferreira

*Facultad de Formación del Profesorado y Educación.  
Universidad Autónoma de Madrid  
Madrid, España  
raquel.menendez@uam.es*

Roberto Ruíz Barquín

*Facultad de Formación del Profesorado y Educación.  
Universidad Autónoma de Madrid  
Madrid, España  
roberto.ruiz@uam.es*

Antonio Maldonado

*Facultad de Formación del Profesorado y Educación.  
Universidad Autónoma de Madrid  
Madrid, España  
antonio.maldonado@uam.es*

David Camacho

*Departamento de Informática  
Universidad Autónoma de Madrid  
Madrid, España  
david.camacho@uam.es*

**Resumen**—El deporte, como uno de los agentes con gran poder de influencia social, está enfrentándose a una serie de amenazas, dentro y fuera de los estadios, y esto se debe al aumento de actos violentos y/o racistas que se producen en los partidos y que se ven intensificados a través del uso de redes sociales. Además hay diversos factores que agravan esta situación: 1) los actos violentos se producen, mayoritariamente, en partidos amateur donde los jugadores no son profesionales; 2) muchas veces estos actos se producen en presencia de niños, que verán estas conductas y comportamientos como normales. Estas acciones ponen de manifiesto la falta de valores sociales que tiene actualmente la población. Valores como la compasión, el respeto, o el civismo, brillan por su ausencia en cada uno de estos actos violentos. En este contexto, la educación en valores desde edades muy tempranas es un elemento clave para abordar esta problemática. No olvidemos que los niños de hoy serán padres el día de mañana, y educarles en valores puede reducir los actos violentos en un futuro cercano. Este trabajo se centra en la revisión de las herramientas tecnológicas actuales dedicadas a la educación en valores. Dado que el grupo objetivo son niños, la herramienta tecnológica seleccionada serán los videojuegos y/o juegos serios. Finalmente, tras analizar algunas de estas herramientas, definiremos una nueva (basada en gamificación) que se desarrollará y se podrá utilizar en un futuro cercano.

**Index Terms**—Educación en Valores, Gamificación, Videojuegos

## I. INTRODUCCIÓN

El deporte se ha convertido en uno de los principales agentes de socialización para muchas personas, influyendo tanto en sus estilos de vida como en forma de relacionarse con los demás. Además de esto, es una herramienta de adquisición de valores [1], [2].

Sin embargo, en las últimas décadas, hemos presenciado una transformación en el sistema de valores de la sociedad en general. Dicha transformación se ha promovido, en parte, por el fenómeno de la globalización, que ha conllevado un aumento de las migraciones, y por otro lado, la aparición de nuevas tecnologías de la información y comunicación (TICs). Generando como resultado un cambio en la forma de comunicarse y de relacionarse que tienen las personas. Estos cambios también han afectado al mundo del deporte, si bien, desde siempre ha existido la rivalidad dentro del deporte, actualmente, estos niveles se han incrementado provocando situaciones violentas, racistas e intolerantes entre jugadores y aficionados, que se ha visto agravada con el uso de las redes sociales [3], [4].

En los últimos años, se han comenzado a tomar medidas encaminadas a eliminar estas conductas. A nivel Europeo se han llevado a cabo iniciativas como “Las Semanas de Acción de los Futbolistas” [5], que reúne a diferentes profesionales del fútbol y público en general durante dos semanas en las que tienen lugar actividades relacionadas con el fútbol y la lucha contra la discriminación. La campaña “*Cuando el racismo gana, el deporte pierde*” en los Países Bajos o “*No al Razzismo*” en Italia son otros ejemplos [4]. En España se podría destacar la campaña “*Cuenta hasta tres*”. En esta campaña se enfatizaron tres puntos: (1) Animar tanto al esfuerzo como al éxito, (2) Respetar las decisiones de los entrenadores y oficiales, y (3) Mostrar deportividad [6]. Por otro lado, el ayuntamiento de Valencia ha puesto en marcha la campaña “*Con respeto ganamos todos*” dirigida al fútbol base (formado por categorías juveniles) que se lleva a cabo en los campos de fútbol municipales de la ciudad de Valencia [7].

Identify applicable funding agency here. If none, delete this.

La mayoría de estas iniciativas están pensadas para ser desarrolladas entre niños y jóvenes. Por lo tanto, la educación desde edades muy tempranas, es un elemento clave a la hora de intentar combatir esta problemática. Según la teoría del aprendizaje social [8] y el desarrollo moral [9], la adquisición de los valores se produce mayoritariamente a través de la observación y la participación activa en la sociedad; y se ve reforzada por adultos o personas significativas para los niños/as como son la familia, los amigos, el profesorado, entrenadores/as, etc. [10], [11]. Por lo tanto, en el mundo del deporte, uno de los principales agentes socializadores son los profesores de educación física y entrenadores, ya que tienen un papel primordial a la hora de crear situaciones de aprendizaje en la que la transmisión de valores éticos y morales ocupan un lugar central.

Por todo esto, resulta necesario crear metodologías innovadoras para motivar a los más jóvenes en el aprendizaje de conductas y valores positivos dentro del deporte. Como estamos en un entorno en el que el juego es el principal protagonista, sería acertado pensar que la utilización de mecanismos basados en el juego, como son los videojuegos, podrían ser un recurso con alto potencial educativo. Por esta razón, este trabajo tiene las siguientes finalidades: (1) identificar investigaciones previas acerca del uso de los videojuegos dentro de la educación física y el deporte, (2) analizar el potencial uso de los videojuegos como recurso educativo para promover valores sociales dentro del deporte, y (3) describir una nueva herramienta basada en videojuego para la adquisición de valores dentro del deporte.

## II. EL USO DE LOS VIDEOJUEGOS EN EDUCACIÓN

Vivimos en una sociedad en constante evolución en la que la utilización de las tecnologías de la información y la comunicación (TICs) están presentes en todos los sectores de nuestra sociedad. Uno de los sectores más influyentes es el de la educación en el cual se deberían incluir metodologías de enseñanza innovadora acordes con las nuevas necesidades de la sociedad. En este sentido, la utilización de nuevas tecnologías y herramientas para la educación se ha extendido a través de la utilización de plataformas de aprendizaje como Moodle<sup>1</sup>, Dokeos<sup>2</sup>, Claroline<sup>3</sup>. Estas plataformas son espacios donde los alumnos no sólo tienen la posibilidad de interactuar con sus compañeros a través del uso de herramientas como blogs, wikis o foros de debate, sino que también pueden interactuar con los contenidos, presentando materiales en distintos formatos (video, audio, objetos de aprendizaje e incluso juegos).

Esta forma de educación, en la que los estudiantes pueden interactuar con los contenidos, está basada en teorías constructivistas de Piaget [12] y Vygotsky [13], que han demostrado que el aprendizaje a través de la experimentación

<sup>1</sup><http://moodle.org>

<sup>2</sup><http://www.dokeos.com>

<sup>3</sup><http://www.claroline.net>

e interacción se adquiere de manera más significativa para el educando. Dentro del constructivismo se considera al estudiante como un sujeto activo que debe construir el conocimiento a través de la interacción con el entorno social. El papel del educador es el de facilitador de herramientas y materiales para la construcción del aprendizaje que debe partir desde los elementos más generales y básicos, a los más concretos y complejos. En este contexto, el uso de tecnologías como mundos virtuales [14] [15] y/o videojuegos son recursos que proporcionan a los educandos entornos de aprendizaje inmersivos en los que pueden interactuar con los objetos y tomar decisiones como si de un contexto real se tratase.

El uso de los videojuegos en los procesos educativos ha aumentado en las últimas décadas. Son numerosas las disciplinas o áreas de investigación que han visto el potencial de los videojuegos como recurso pedagógico [16]. Actualmente existen numerosas metodologías basadas en el uso de los videojuegos y sus elementos, siendo las más destacadas “gamificación” [17], [18], “juegos serios” [19], [20], “Game-Based learning (GBL)” [21], o “mundos virtuales” [14] entre otros. Incluso podríamos destacar algunos juegos comerciales que se han utilizado en la práctica educativa como son “*Age of Empires*”, “*Civilization IV*” para la enseñanza de historia, “*The Sims*” y “*World Of Warcraft*” para la enseñanza de idiomas [22].

El primer uso documentado del término “gamificación” fue en 2008 y se definió como “el uso de los elementos de diseño de juegos (rankings, medallas, avatares, recompensas, puntos, etc.) en contextos ajenos al juego” [23]. El principal objetivo de la gamificación es motivar e incrementar el compromiso de las personas en el aprendizaje o realización de una tarea. En el estudio realizado por Hamari, Koivisto y Sarsa [24], se muestra cómo la implementación de las técnicas de gamificación en el campo de la educación ha tenido resultados positivos. Esto se debe a que, mediante la utilización de estos recursos, los niños se sienten más motivados y predispuestos a completar las actividades o desafíos propuestos. En este trabajo nos vamos a centrar en la gamificación como recurso educativo para motivar a los estudiantes en el aprendizaje de valores.

## III. POTENCIAL DE LOS VIDEOJUEGOS EN LA EDUCACIÓN FÍSICA Y DEPORTE

El uso de videojuegos como recurso educativo para la enseñanza de la educación física ha crecido en los últimos años y son numerosos los profesionales y educadores que han puesto su interés en ellos [25]–[27]. Algunos de estos estudios han demostrado el potencial de los videojuegos en el campo de la educación física y el deporte (en general) como recurso educativo para mejorar las capacidades espaciales, las estructuras de conocimiento, la atención visual selectiva y las habilidades de resolución de problemas [25]. Se puede decir,



Cuadro I  
CATEGORÍAS DE VIDEOJUEGOS DEPORTIVOS Y SU POTENCIAL EDUCATIVO

Tipo de videojuego	Definición	Ejemplo de juego	Competencias/habilidades
Simulación	Diseñados para simular aspectos de un entorno real o ficticio.	EA Sports Fifa, Madden NFL, la serie de NBA 2k, NBA Live	Toma de decisiones, análisis de las acciones y estrategias seguidas, aprendizaje sobre terminología deportiva, reglas, técnicas deportivas específicas y tácticas deportivas, trabajo en equipo y estímulo para las relaciones interpersonales.
Arcade	El objetivo principal es obtener una puntuación alta. A menudo tienen niveles cortos, esquemas de control simples e intuitivos, y dificultad incremental a corto plazo.	NFL Blitz, NBA Jam, Virtual tennis 1999.	Aprendizaje sobre terminología deportiva, reglas, técnicas, resolución de problemas, toma de decisiones, reflexión sobre las tácticas, cooperación y desarrollo de la motricidad fina.
Dirección o gestión deportiva	Ponen a los jugadores en el papel del entrenador de equipo, donde se espera que los jugadores realicen fichajes de jugadores, definan las estrategias y tácticas deportivas y se encargue de cuestiones financieras.	Football Manager, SimLeagues, Comu-nio, World Basketball Manager	Toma de decisiones, responsabilidad social y financiera, resolución de problemas, terminología deportiva, conocimiento técnicas deportivas específicas, desarrollar y probar hipótesis.
Exergames	Son videojuegos interactivos que potencian y motivan la actividad física en las personas mediante tecnologías que monitorizan los movimientos del cuerpo.	Wii fit, EA Sports active, Dance Dance Revolution.	Mejora de las habilidades motoras gruesas y finas, equilibrio y coordinación ojo-pie y ojo-mano.

por lo tanto, que con el uso de los videojuegos de deportes se estarían desarrollando muchas de las competencias clave que actualmente están incluidas en el curriculum oficial de educación [28].

La mayor parte de la literatura relacionada con los videojuegos y la educación física se centra en el uso de los productos denominados *Commercial off-the-shelf (COTS)*, definidos como los juegos comerciales. Dentro de los deportes, estos tipos de juego ofrecen un entorno de simulación realista de diferentes entornos deportivos (fútbol, tenis, etc.) con el fin de entender sus reglas, gestionar equipos, mejorar la motivación y el rendimiento en las actividades deportivas. Pero también existen los juegos llamados *exergames* que promueven el ejercicio físico mediante ejercicios aeróbicos interactivos, que favorecen la tonificación muscular, etc. [26]. En el estudio realizado por Young et al. [22] se muestra algunos ejemplos del uso de exergames en la educación física.

Dentro de los videojuegos de deportes podemos distinguir 4 tipos de videojuegos: simulación, arcade, dirección o gestión deportiva y exergames [26]. El Cuadro I, muestra un resumen de las principales categorías de los videojuegos de deportes, en la que se pueden ver ejemplos de videojuegos (extraídos de la literatura científica) pertenecientes a cada categoría y su potencial educativo.

Un ejemplo de cómo utilizar un videojuego deportivo, como el NBA Live 07, como recurso educativo en un aula de educación primaria lo encontramos en el libro de Lacasa [29]. En este trabajo se propone un taller dividido en 4 fases, que se podrían aplicar en el uso de cualquier otro videojuego de deporte:

- **Fase 1:** introducción en la que se explicaba el motivo por el que se iba a utilizar el videojuego como instrumento

educativo, dejando claro que no sólo se trataba de jugar, sino que debían reflexionar y pensar con los juegos.

- **Fase 2:** jugar y reflexionar sobre las reglas del juego virtual y las reales.
- **Fase 3:** los estudiantes tenían que publicar y expresar sus opiniones en diversos medios.
- **Fase 4:** evaluar y recopilar las actividades mediante la elaboración de un póster grupal para dar a conocer la actividad del taller.

#### IV. VIDEOJUEGOS PARA PROMOVER VALORES SOCIALES

A pesar de lo descrito en la sección anterior, en este trabajo estamos interesados en aquellos videojuegos que se han utilizado como medio educativo para promover valores sociales y mejorar conductas y/o actitudes de las personas. En relación a esto, Wouters et al. [30] han desarrollado un estudio sobre el uso de los juegos serios desde la perspectiva de los resultados del aprendizaje. Para este estudio fijaron 4 tipos de resultados de aprendizaje que los juegos podrían tener: a) cognitivo (conocimiento codificado y habilidades cognitivas), b) habilidades motoras, c) aprendizaje afectivo y d) aprendizaje comunicativo.

En relación con los resultados del aprendizaje afectivo, en el que se pueden cambiar comportamientos y conductas de las personas, existen videojuegos para superar miedos y fobias como el juego *Half-Life* para superar el miedo a las arañas, o el videojuego *London Racer* [30] para los que tienen fobia a los accidentes de tráfico. En ambas experiencias, se extrajeron resultados positivos y un cambio de actitud relacionado con sus miedos y fobias. Es por ello que el uso de videojuegos podría afectar a los comportamientos y actitudes de las

INICIO **NUEVO EQUIPO** UNIR EQUIPO EVALUAR EQUIPO EVALUACIONES SALIR

## NUEVO EQUIPO

Crear un nuevo equipo introduciendo su nombre, el de sus componentes y los valores que se van a evaluar:

Equipo

**Jugadores**

Nombre	Apellido	Edad	
<input type="text"/>	<input type="text"/>	<input type="text"/>	
<input type="text"/>	<input type="text"/>	<input type="text"/>	

**Valores**

<input checked="" type="checkbox"/> Deportividad	<input type="checkbox"/> Obediencia	<input type="checkbox"/> Cohesión de equipo	<input type="checkbox"/> Imagen social	<input type="checkbox"/> Autorrealización
<input type="checkbox"/> Preocupación por los demás	<input type="checkbox"/> Actuación Pacífica	<input type="checkbox"/> Conformidad	<input type="checkbox"/> Ventaja de equipo	<input type="checkbox"/> Conciencioso
<input type="checkbox"/> Equidad-Justicia	<input type="checkbox"/> Agresividad	<input type="checkbox"/> Acogida	<input type="checkbox"/> Superioridad de equipo	<input type="checkbox"/> Responsabilidad Social
<input type="checkbox"/> Tolerancia	<input type="checkbox"/> Individualismo	<input type="checkbox"/> Ayuda/Compasión	<input type="checkbox"/> Mostrar habilidades	<input type="checkbox"/> Forma Física
<input type="checkbox"/> Apoyo emocional	<input type="checkbox"/> Utilidad	<input checked="" type="checkbox"/> Compañerismo	<input type="checkbox"/> Mantenimiento de contrato	<input type="checkbox"/> Diversión en el juego
<input checked="" type="checkbox"/> Respeto				
<input type="checkbox"/> Responsabilidad				

Figura 1. Aplicación web para crear equipos y seleccionar los valores a evaluar.

personas y, por lo tanto, podría usarse como una herramienta para promover valores.

Un ejemplo de juego que promueve valores sociales y culturales es el proporcionado por Paracha et al. [31], que desarrollaron un juego serio conocido como *Shimpai Muyou!*. Es un juego centrado en la educación contra el acoso islámico. Este juego promueve la cultura y los valores del Islam y para ello hace uso de conceptos instructivos y narrativos para enseñar a niños/as (8-12 años) a manejar situaciones emocionalmente sensibles que se pueden dar en las escuelas, mediante dilemas éticos. En este juego los niños tienen que tomar decisiones difíciles, definir estrategias y enfrentarse a las consecuencias de sus acciones. Los resultados de este proyecto fueron positivos e influyeron en la percepción de los niños sobre la intimidación, produciéndose así un aumento en la conciencia, la comprensión moral y la empatía hacia las personas que sufren acoso [31].

El juego serio conocido como *Stoa de Attalosis* es otro ejemplo presentado por Koutsaftis [32]. El objetivo principal de este juego es sensibilizar al público sobre los fundamentos de la teoría y práctica de la Conservación: el sistema de valores patrimoniales y el concepto de autenticidad y cómo afectan sus decisiones y acciones al medio ambiente y el entorno dentro del juego. Idealmente, los usuarios adquirirán, a través de una experiencia de juego recreativo, una impresión general de cómo evolucionaron los valores y la autenticidad durante

el siglo XX y, en última instancia, desarrollarán un conjunto de herramientas críticas con el fin de poder formarse sus propias opiniones personales sobre los asuntos del patrimonio.

Como se puede observar, en algunos de estos ejemplos se han desarrollado videojuegos específicamente para la enseñanza de unos determinados valores. Sin embargo, en la literatura científica relativa al uso de videojuegos de deportes para la educación física apenas hay videojuegos deportivos diseñados con este propósito, simplemente, se adquieren conocimientos relativos a las reglas y términos propios de un determinado deporte y promueven la toma de decisiones y el trabajo cooperativo. Además de esto, existe una gran cantidad de valores de suma importancia para la convivencia que no están representados, o no son transmitidos ni por los videojuegos que se han descrito anteriormente ni por los serious games diseños con propósitos educativos. Por lo tanto, surge la necesidad de desarrollar una herramienta basada en videojuegos deportivos para la adquisición de valores y cuyo uso sea general, o independiente del valor, o valores, que se quieran desarrollar.

## V. SISTEMA BASADO EN GAMIFICACIÓN PARA PROMOVER VALORES DENTRO DEL DEPORTE

En esta sección se describe y se propone una nueva metodología basada en gamificación para promover valores dentro del deporte. La principal característica de esta



## EVALUAR EQUIPO

Selecciona un equipo en la tabla para evaluar sus jugadores. Después usa los valores para puntuar los valores de cada jugadores. Las puntuaciones mejoran hacia la derecha.

Nombre del equipo	Código
AUTÓNOMA(UAM)	
prueba	
Infantil_1B	66607284BFD
Nombre del equipo	Código

### INFANTIL\_1B

Jugador 1	Jugador1
Infantil_1B1	
Deportividad	1 2 3 4 5 6 7 8 9 10
Compañerismo	1 2 3 4 5 6 7 8 9 10
Responsabilidad Social	1 2 3 4 5 6 7 8 9 10
Respeto	1 2 3 4 5 6 7 8 9 10
Responsabilidad	1 2 3 4 5 6 7 8 9 10

Figura 2. Aplicación web para evaluar a cada estudiante.

metodología es la utilización de un videojuego de fútbol para motivar a los niños/as el aprendizaje de valores presentes en un contexto deportivo.

Cabe resaltar que este sistema de gamificación, se desarrolla dentro de un proyecto europeo denominado SAVEit<sup>4</sup> (579893-EPP-1-2016-2-ESPOSCP) en el que participan diferentes clubes deportivos de toda Europa. El objetivo principal de este proyecto es el de diseñar una metodología de aprendizaje orientada al deporte para reducir la violencia, el racismo y la discriminación, promoviendo el reconocimiento de los valores positivos del deporte y enseñándolos a los principales grupos destinatarios (niños, jóvenes, entrenadores y padres). Para ello, se han diseñado dos tipos de materiales didácticos:

- Por un lado, diseñar un curso on-line mediante el cual los profesores/entrenadores van a adquirir las competencias necesarias para la formación en valores. A través de esta formación aprenderán cómo promover valores durante sus entrenamientos. Dispondrán de 8 módulos de formación. Los primeros módulos serán la introducción y metodología a seguir y el resto versa sobre los valores deportivos a estudiar (Respeto, Compañerismo, orden, hábitos saludables y convivencia). Estos tendrán un contenido teórico acerca del valor a desarrollar, dónde se podrá conocer más a fondo el concepto y sus peculiaridades, así como, se presentan actividades y juegos diseñados para poner en práctica dichos valores. Finalmente se dotan a los profesores/entrenadores de instrumentos para evaluar la evolución de los valores de los niños/as.
- Por otro lado, el desarrollo de un videojuego basado en el fútbol que estará conectado con las actitudes y comportamientos de los niños/es durante los entrenamientos y servirá de elemento motivador para que los niños/as se impliquen en el desarrollo de los juegos y actividades

propuestas, así como, provocar cambios de conductas y actitudes.

El videojuego propuesto está basado en fútbol y en él cada niño va a tener un equipo. Como todo videojuego, tanto el personaje principal como los NPC (del inglés *Non-Play Character*) tendrán un conjunto de características que definirán su comportamiento. Por ejemplo, en el fútbol estas características pueden ser: resistencia, la velocidad, la potencia de los tiros de los jugadores o la precisión de los pases. El aspecto innovador de esta metodología es que estas características funcionarán mejor o peor dependiendo de la actitud y comportamiento de los niños/as durante los entrenamientos (esto será evaluado por los entrenadores y/o profesores).

Trás la creación del videojuego de fútbol, el siguiente paso fue el de diseñar una aplicación web que conectase el comportamiento y valores de los niños con el videojuego. Se creó una aplicación para los entrenadores donde deben crear los diferentes equipos de fútbol y añadir a los niños/as o jóvenes a cada uno de esos equipos, en la Figura 1 podemos ver una captura de pantalla de la aplicación web donde podemos ver que los entrenadores/profesores pueden seleccionar los valores que van a trabajar y evaluar en los niños.

Una vez diseñadas todas las herramientas tecnológicas, los entrenadores/profesores realizarán el curso online de formación de valores. Después, en sus sesiones de entrenamiento, implementarán actividades y juegos para que los alumnos entiendan los diferentes valores, los pongan en práctica y/o se enfrenten a situaciones donde la presencia (o ausencia) de estos valores sea un factor clave.

En la última fase, los profesores son los encargados de evaluar el grado en el cual los valores han sido adquiridos por los estudiantes (ver Figura 2). Esta evaluación se realizará

<sup>4</sup><http://saveitproject.eu>



Figura 3. Captura de la interfaz del videojuego donde se puede ver los puntos a repartir.

dentro de la aplicación web (mencionada anteriormente) que estará conectada al videojuego. La evaluación se traducirá en una puntuación de entre 2 y 20 puntos que los niños/as deberán distribuir entre las 5 características técnicas del equipo virtual [33], en la Figura 3 podemos ver una captura de pantalla del interfaz del videojuego y cómo se puede distribuir los puntos.

La particularidad de la herramienta es que la cantidad de puntos que los estudiantes vayan a tener, va a depender de la adquisición de los valores específicos en su día a día. Es decir, una vez los profesores adquieren y trabajan con los estudiantes diferentes valores, los profesores serán los encargados de evaluar dichas aptitudes en los estudiantes. Por ejemplo, verán cómo se comportan con los compañeros, qué valores tienen mientras entrenan, en los partidos oficiales, etc. En función de su comportamiento moral en su día a día, tendrán más o menos puntos en el videojuego, de manera que el rendimiento de su equipo virtual será mejor o peor.

Por último, también se propone una liga virtual entre todos los miembros de un equipo. De manera que los resultados de los equipos de los estudiantes dentro del videojuego, afecten a esa liga y así los estudiantes disponen de una competición donde el mejor tenga una recompensa.

## CONCLUSIONES

La educación en valores en el ámbito de la educación física y el deporte es un asunto que, aunque preocupa a los docentes y entrenadoras, todavía existen pocas prácticas educativas diseñadas específicamente para la promoción de valores en el deporte. En muchos países europeos, el desarrollo social y moral a través de la educación física es una parte fundamental de su currículo [34]. Por esta razón es necesario fomentar, entre docentes y entrenadores, la creación y desarrollo de enfoques innovadores para educar en valores.

Como se ha podido constatar a lo largo de este trabajo, los videojuegos ya se presentan como una herramienta con alto potencial educativo y de cambio social. Sin embargo, es necesario remarcar, que el uso de los videojuegos en las aulas, siempre, debe realizarse de manera planificada y organizada, atendiendo a unos objetivos de aprendizaje y/o competencias prefijadas de antemano. Sólo de esta manera se podrán conseguir buenos resultados.

En un futuro próximo, el sistema de gamificación presentado en este trabajo se probará en contextos reales con diferentes clubes de fútbol que actualmente forman parte del consorcio del proyecto SAVEit. La evaluación de la herramienta se realizará a través de los resultados obtenidos de un cuestionario pre-test y otro post-test, donde se podrá ver evaluación de los valores de los niños/as. Y finalmente, se analizarán los datos almacenados en el videojuego y en las evaluaciones de los niños/as dentro de la aplicación web.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto SAVE IT: “Saving the dream of grassroots sport based on values” en el marco del programa Erasmus+ SPORT 2016, Support to Collaborative Partnerships action (579893-EPP-1-2016-2-ES-SPOSCP)

## REFERENCIAS

- [1] M. G. Sanmartin, “El valor del deporte en la educación integral del ser humano,” *Revista de Educacion*, vol. 335, pp. 105 – 126, 2014.
- [2] S. Greedorfer, “Sport socialization,” in *Advances in short psychology*, T. Horn, Ed. Champaign, IL: Human Kinetics, 1992, pp. 201–218.
- [3] R. Llopis-Goig, “Racism and Xenophobia in Spanish Football: Facts, Reactions and Policies,” *Physical Culture and Sport Studies and Research*, vol. 47, no. 1, pp. 35–43, 2009.
- [4] J. Marsh, P. Fox, K. Carnibella, G., McCann, J. and Marsh, *Football Violence and Hooliganism in Europe*. The Amsterdam Group, 2005. [Online]. Available: <http://www.sirc.org/publik/fvracism.html>
- [5] Fare Networks, “Football People action weeks,” 2015. [Online]. Available: <http://farenet.org/resources/football-people-action-weeks/>
- [6] C. L. Cruz Jaume, Boixadós Mercé, Veliente Lourdes, “Prevalent Values in Young Spanish Soccer Players,” *International Review for the Sociology of Sport*, vol. 30, no. 3-4, pp. 353–371, 1995.
- [7] Ayuntamiento de Valencia, “Con respeto ganamos todos”. Plan de prevención de la violencia en el Fútbol Base,” 2018. [Online]. Available: <http://www.futbolconrespeto.com>
- [8] A. Bandura, *Teoría del Aprendizaje Social*. Madrid: Espasa-Calpe, 1982.
- [9] L. Kohlberg and R. H. Hersh, “Moral development: A review of the theory,” *Theory Into Practice*, vol. 16, no. 2, pp. 53–59, 1977.
- [10] J. A. Cecchini Estrada, A. Méndez-Giménez, and J. Fernández-Río, “Meta-percepciones de competencia de terceros significativos, competencia percibida, motivación situacional y orientaciones de deportividad en jóvenes deportistas,” *Revista de Psicología del Deporte*, vol. 23, no. 2, pp. 285–293, 2014.
- [11] A. Rodríguez-Groba, R. Eirín-Nemíña, and A. Alonso-Ferreiro, “Materiales y recursos didácticos contra la discriminación y la exclusión en el deporte en edad escolar,” *Education Siglo XXI*, vol. 35, no. 3 Noviembre, p. 85, 2017.
- [12] J. Piaget, *Psicología y pedagogía*. Barcelona: Ariel, 1980.
- [13] L. Vygotsky, *El desarrollo de los procesos psicológicos superiores*. Barcelona: Grijalbo, 1979.
- [14] A. Berns, A. Gonzalez-Pardo, and D. Camacho, “Game-like language learning in 3-D virtual environments,” *Computers and Education*, vol. 60, no. 1, pp. 210–220, 2013.



- [15] A. González-Pardo, A. Rosa, and D. Camacho, "Behaviour-based identification of student communities in virtual worlds," *Computers Science and Information Systems*, vol. 11, no. 1, pp. 195–213, 2014. [Online]. Available: <http://dx.doi.org/10.2298/CSIS130214003G>
- [16] M. D. Griffiths, "The educational benefits of videogames," *Education and health*, vol. 20, no. 3, pp. 47–51, 2002.
- [17] B. Sawyer and P. Smith, "Serious games taxonomy," in *Serious Games Summit, at the Game Developers Summit*, San Francisco, 2008, pp. 1–54. [Online]. Available: <https://thedigitalentertainmentalliance.files.wordpress.com/2011/08/serious-games-taxonomy.pdf>
- [18] K. Werbach and D. Hunter, *The gamification toolkit: dynamics, mechanics, and components for the win.*, wharton di ed., 2015.
- [19] J. Breuer and G. Bente, "Why so serious? On the Relation of Serious Games and Learning," vol. 4, no. 1, pp. 7–24, 2010.
- [20] D. Michael and S. Chen, "Serious Games: Games That Educate, Train, and Inform," Boston, p. 305, 2006.
- [21] K. Corti, "Game-based Learning a serious business application." *Informe de PixelLearning*, vol. 34, no. 6, pp. 1–20, 2006.
- [22] M. F. Young, S. Slota, A. B. Cutter, G. Jalette, G. Mullin, B. Lai, Z. Simeoni, M. Tran, and M. Yuhymenko, "Our Princess Is in Another Castle: A Review of Trends in Serious Gaming for Education," *Review of Educational Research*, vol. 82, no. 1, pp. 61–89, 2012.
- [23] S. Deterding, D. Dixon, R. Khaled, and L. Nacke, "From game design elements to gamefulness: Defining gamification," in *Proceedings of the 15th International Academic MindTrek Conference: Envisioning Future Media Environments*. ACM, 2011, pp. 9–15.
- [24] J. Hamari, J. Koivisto, and H. Sarsa, "Does gamification work? — a literature review of empirical studies on gamification," in *47th Hawaii International Conference on System Science*, 2014, pp. 3025–3034.
- [25] E. Hayes and L. Silberman, "Incorporating video games into physical education," *Journal of Physical Education*, vol. 78, no. February, pp. 18–24, 2007.
- [26] M. Pivec, B. Hable, and D. Coakley, "Serious sports: Game-based learning in sports," *15th International Conference on Interactive Collaborative Learning, ICL*, 2012.
- [27] M. Papastergiou, "Exploring the potential of computer and video games for health and physical education: A literature review," *Computers & Education*, vol. 53, pp. 603–622, 2009.
- [28] Boletín Oficial del Estado, "Orden ECD/65/2015, de 21 de enero, por la que se describen las relaciones entre las competencias, los contenidos y los criterios de evaluación de la educación primaria, la educación secundaria obligatoria y el bachillerato." pp. 6986–7003, 2015. [Online]. Available: [http://www.boe.es/diario\\_boe/txt.php?id=BOE-A-2015-738](http://www.boe.es/diario_boe/txt.php?id=BOE-A-2015-738)
- [29] P. Lacasa, *Los videojuegos. Aprender en mundos reales y virtuales*. Madrid: Morata, 2011.
- [30] P. Wouters, H. Van Oostendorp, and E. D. Van Der Spek, "Game design: The mapping of cognitive task analysis and Game Discourse Analysis in creating effective and entertaining serious games," in *ECCE 2010 - European Conference on Cognitive Ergonomics 2010: The 28th Annual Conference of the European Association of Cognitive Ergonomics*, 2010, pp. 287–293.
- [31] S. Paracha, S. Jehanzeb, and O. Yoshie, "A Serious Game for Inculcating Islamic Values in Children," in *Proceedings - 2013 Taibah University International Conference on Advances in Information Technology for the Holy Quran and Its Sciences, NOORIC 2013*, 2015, pp. 172–177.
- [32] C. Koutsafitis and A. Georgopoulos, "A serious game in the Stoa of Attalos: Edutainment, heritage values and authenticity," in *Proceedings of 2nd International Congress on Digital Heritage, 28 September–2 October*, Granada, Spain, 2015, pp. 751–752.
- [33] R. Menéndez-Ferreira, R. Ruíz Barquín, A. Maldonado, and D. Camacho, "Education in sports values through gamification," in *Proceedings of INTED2018 Conference on 5th-7th March 2018, Valencia, Spain*, 2018, pp. 6139–6147.
- [34] R. Bailey, K. Armour, D. Kirk, M. Jess, I. Pickup, R. Sandford, and B. P. Education, "The educational benefits claimed for physical education and school sport: an academic review," *Research papers in education*, vol. 24, no. 1, pp. 1–27, 2009.

# *Inducción de emociones a través del diseño de videojuegos*

## *Una revisión del estado del arte*

Javier Torregrosa

Departamento de Psicología Biológica y de la Salud  
Universidad Autónoma de Madrid, Madrid, España, 28049.  
francisco.torregrosa@uam.es

Gema Bello-Orgaz

Departamento de Ingeniería Informática  
Universidad Autónoma de Madrid, Madrid, España, 28049.  
gema.bello@uam.es

Raúl Lara-Cabrera

Departamento de Ingeniería Informática  
Universidad Autónoma de Madrid, Madrid, España, 28049.  
[raul.lara@uam.es](mailto:raul.lara@uam.es)

Pei-Chun Shih

Departamento de Psicología Biológica y de la Salud  
Universidad Autónoma de Madrid, Madrid, España, 28049.  
pei\_chun.shih@uam.es

**Abstract**— Las emociones han demostrado ser una variable clave a la hora de diseñar un juego. Sin embargo, aunque existen cada vez más investigaciones relacionando videojuegos y variables emocionales, dichos artículos adoptan diversos enfoques y abordajes, por lo cual la bibliografía sobre la elicitación de emociones en juegos se encuentra fragmentada. El objetivo de este artículo es unificar, de manera comprensiva, los distintos resultados en función de su temática y su impacto, con el fin de facilitar a los diseñadores la comprensión de la relación entre las variables del juego y las emociones. Para ello, se realizará una revisión teórica de estudios centrados en la inducción de emociones en jugadores, presentando un total de 49 artículos divididos en 9 campos: personajes, frustración, género, gráficos, inmersión, eventos del juego, componente social, sonido y contenido violento.

**Keywords**—emociones; videojuegos, diseño, estado emocional, affective gaming.

### I. INTRODUCCIÓN

Las emociones son un proceso clave dentro de la valoración y experiencia de un usuario en relación con un videojuego [1]. Como puede comprobarse a través de la literatura [2], los juegos tienden a actuar como un catalizador (ya desde niños) para generar emociones positivas en los individuos. Por lo tanto, el poder generar estados emocionales adquiere gran importancia como medio de generar interés por un producto. Si además tenemos en cuenta que solo en el año 2016, los videojuegos ya eran utilizados por más de 2000 millones de personas en todo el mundo, [3], podemos entender que esto provoque que la emoción en los videojuegos haya pasado de verse como un “elemento secundario” (o consecuencia) a verse

como parte esencial en el proceso de atracción del jugador y de generación de interés en el producto [4].

El campo de estudio relacionado con las emociones y su impacto en el jugador ha crecido tanto que, incluso, se han desarrollado análisis específicos sobre cómo adaptar los propios juegos a las emociones de los usuarios. Dicha rama, conocida como Juego Afectivo (Affective Gaming) [5], supone dotar a los propios juegos de la capacidad de 1) detectar las emociones que el jugador manifiesta, ya sea a través del comportamiento o de variables fisiológicas, y 2) adaptarse a las mismas, generando cambios en el propio juego con el fin de mejorar la experiencia de juego.

El desarrollo del Affective Gaming como disciplina académica del estudio de las emociones en los videojuegos, ha centrado el interés de la investigación por algunas partes concretas del proceso (medición y adaptación). Esto ha dado pie a gran cantidad de estudios sobre cómo medir emociones y cómo adaptar el juego a las mismas. La base psicológica de dichos estudios, así como su enfoque a la hora de capturar la emoción, se resume en el planteamiento de Madeira, Arriaga, Adrião, Lopes y Esteves [6]:

- La emoción puede estudiarse desde dos perspectivas fundamentales. Por un lado, el enfoque dimensional, planteado originalmente por Wundt [7], defiende que el estado emocional puede definirse en base al *arousal* (activación cerebral alta o baja), valencia emocional (positiva como la alegría, o negativa como la ira) y dominancia (alta o baja, relacionado con el control del sujeto sobre la emoción). Por otro lado, el enfoque categórico, especialmente conocido tras el trabajo de Ekman [8], plantea que existen una serie de emociones



cerradas. Las más consensuadas son las llamadas emociones básicas (alegría, tristeza, enfado, ira y asco<sup>1</sup>).

- Por otro lado, la emoción del jugador puede ser recogida de tres maneras distintas (o a través de una combinación de las mismas): fisiológica (cambios biológicos), auto-informada (cuestionarios y entrevistas) y observacional (expresión facial).

Sin embargo, mientras que se han estudiado los procesos de recogida de la emoción y cambios dentro de la jugabilidad, los planteamientos más básicos que sustentan dicha perspectiva de estudio, como qué elementos del juego generan una emoción en el individuo, parecen haber quedado en segundo plano. Aunque hay trabajos teóricos que recogen resultados previos de investigaciones empíricas sobre elicitación de emociones en videojuegos [6], dichos trabajos no recogen los resultados de los últimos años de investigación, estando además centrados en aportar una visión global del campo, más que en hablar de resultados concretos. Precisamente la división que realizan Madeira y colaboradores [6] permite sentar las bases antes de analizar los estudios empíricos existentes en el campo de la elicitación de emociones en los videojuegos. La mayor parte de las investigaciones (como se puede comprobar en los resultados de esta revisión) enfocan sus fundamentos en algún elemento de estas dos dimensiones. Esto provoca, a su vez, que pueda generarse un cuerpo de conocimientos comunes que puedan compartirse y combinarse entre sí con el fin de mejorar el diseño de un juego, de cara a la elicitación emocional.

El presente artículo nace con el fin de reducir la dispersión de la literatura existente en torno a la elicitación de emociones. Su objetivo es presentar, de manera ordenada, qué elementos de los videojuegos han demostrado ser útiles para provocar un cambio en el estado emocional, en base a la investigación científica sobre los mismos. Para ello, se realizará una recopilación de bibliografía que tratan la generación de emociones a través de variables del juego, para posteriormente agrupar los resultados y aportar una visión global sobre cómo el diseño de un videojuego puede generar (o no) emociones.

## II. METODOLOGÍA DE REVISIÓN

La metodología seguida para la recolección de artículos consistió en un procedimiento de revisión sistematizada, a través del cual se obtuvieron, cribaron y analizaron un total de 49 artículos relacionados con la elicitación emocional y su relación con las características de los videojuegos. El procedimiento seguido se recoge, brevemente, a continuación.

### A. Fase de búsqueda

Utilizando los tesauros “Video games” y “Emotion”) de manera combinada, se realizó una búsqueda por abstract, keywords y título en tres bases de datos: Scopus, ScienceDirect

<sup>1</sup> Aunque la sorpresa suele considerarse como parte de las emociones básicas, el poco acuerdo de los científicos sobre esta emoción provoca que la misma no sea incluida como emoción básica.

y ProQuest (que a su vez incluía Psycarticles y PsycInfo). La única limitación impuesta a dicha búsqueda fue de idioma (lengua inglesa o española). El total de artículos final de la búsqueda (tras eliminar los artículos repetidos) dejó un total de 915 artículos.

### B. Criterios de cribado

Se estableció un criterio sobre inclusión/rechazo de artículos con el fin de sistematizar el proceso de cribado. Pueden comprobarse dichos criterios a continuación:

- Se aceptaban aquellos artículos que tuvieran que ver con la relación entre características del juego y generación de emociones.
- Se aceptaba cualquier enfoque para el documento aceptado, ya fuera empírico o teórico (siempre que este último recogiera referencias), incluyendo a su vez tesis doctorales.
- No se tuvieron en cuenta aquellos artículos que analizaran la recogida de emociones, el impacto en la conducta de juego o la experiencia final del mismo.
- Fueron descartados todos aquellos artículos que hablaban de población no sana, incluyendo aquellos que trataban los juegos como tratamiento, terapia o entrenamiento.

### C. Resultados del proceso.

Tras realizar el procedimiento, se dividieron los 49 documentos restantes en función de su temática (quedando la misma escogida a discreción de los autores, en función del tema específico tratado por cada documento). En la Tabla 1 puede comprobarse el resultado de dicho análisis.

Tabla 1. Distribución de artículos por temática.

<u>Temática</u>	<u>Artículos</u>
Personajes	4
Frustración	6
Género	8
Gráficos	5
Inmersión	9
Eventos del juego	4
Componente Social	3
Sonido	3
Contenido violento	7

## III. RESULTADOS

Una vez concluida la selección de los artículos y su categorización por temática, comenzó el proceso de extracción de información de los mismos. A continuación, se dividen sus conclusiones en función de la categoría a la que pertenecen. Es

importante añadir que alguno de ellos puede pertenecer a varias categorías, dado su contenido. En dicha situación, el artículo será nombrado en las distintas categorías que trate.

**Personajes:** si bien la mejora gráfica de los personajes no parece afectar al aumento de la elicitación de emociones, el paso del tiempo sí parece ser útil para crear un lazo emocional [9]. También los actos de violencia injustificada llevada a cabo por los personajes afectan (negativamente) a las sensaciones de culpabilidad del jugador [10]. Sin embargo, no parece que la expresión del miedo [11] en los personajes afecte a la sensación de miedo de los jugadores (incluso llega a suceder lo contrario). Por último, utilizando el enfoque Kansei, se ha realizado una taxonomía sobre qué variables emocionales deben tenerse en cuenta para desarrollar un avatar. Tomando con precaución los resultados de dicho estudio (dada su metodología poco habitual y cualitativa), dichas variables se reducen a 4 factores: inteligencia y confiabilidad, aventurero, confianza en sí mismo y atractivo [12].

**Frustración:** la frustración se encuentra asociada a la dificultad percibida en el juego. El hecho de aumentar la misma, ya sea por inexperiencia del jugador [13] o por una voluntad del diseñador de dificultarlo con trampas [14], provocan un aumento de dicha frustración. Dicho aumento se traduce en una disminución de la emoción de alegría [15], un aumento del arousal [16] y un aumento de tendencia negativa de la valencia emocional [13]. La posibilidad de repetir el nivel, sin embargo, provoca una disminución de las emociones negativas derivadas de dicha frustración [17]. Por último, también se ha encontrado que el aburrimiento por contenido repetido (por ejemplo, de niveles) también se relaciona con la frustración [18].

**Género:** los resultados de un estudio de Mehrabian y Wixen [19], si bien algo desactualizados, demuestran que los juegos solían generar un nivel de arousal medio, dominancia media y valencia negativa. Sin embargo, eran aquellos que generaban arousal, dominancia y valencia elevados los que más gustaban. Esta tendencia se ve reforzada parcialmente con el estudio de Ravaja, Salminen, Holopainen, Saari, Laarni, y Järvinen [20], que demostró que, de cuatro juegos (Tetris, Super Monkey Ball 2, Monkey Bowling 2 y James Bond: Nightfire), el Nightfire era el preferido (pese a ser el que más estrés influía en los jugadores, con emociones de diversos tipos y arousal elevado).

Ahondando más en el género del juego, se detectó también que jugar a juegos violentos, frente a los no agresivos, generaba un mayor estrés en la voz [21]. Esto también se comprobó en juegos online violentos, que también provocaban un aumento del estrés, así como de la activación (arousal) del individuo [22]. Esta activación generada por los juegos violentos, sin embargo, provocaba una reducción de la hostilidad y el estrés a largo plazo. Por tanto, aunque los juegos violentos generen estrés, también sirven como canalizadores del mismo [23], e incluso como posibles

facilitadores de emociones, tanto positivas como negativas [24]. Finalmente, los llamados "exergames" (Exercise Games) tuvieron resultados aparentemente contradictorios, pero mostraron un patrón que se repite en otros estudios: los usuarios presentaban emociones positivas al ocurrir eventos positivos, pero en ocasiones también al ocurrir eventos negativos [25]. Se demostró, a su vez, que jugar durante una temporada a este género de juegos aumentaba significativamente la frecuencia de emociones positivas y disminuía las emociones negativas [26].

**Gráficos:** El estudio de Geslin, Jégou y Beaudoin [27], además de aportar un interesante modelo sobre el uso de los colores para generar emociones, llegó a una conclusión: a mayor variedad de colores y más brillo, mayor aumento del arousal y mayor positividad de la valencia. Precisamente, la influencia del brillo en las emociones ya había sido sugerida anteriormente a nivel teórico [28]. Más discretos son los resultados de Joosten, Van Lankveld y Spronck [29], que encuentran que el rojo evoca mayor arousal y valencia negativa, mientras que el amarillo genera mayor emoción positiva en jugadores novatos. Cuando se hizo la prueba sobre un mismo escenario [30], presentando una versión oscura, con niebla y con ruidos de animales nocturnos, frente otra más clara y colorida con los sonidos de un bosque diurno, los usuarios indicaron que la versión colorida les transmitía mayor sensación de paz (aunque estos resultados, nuevamente, se basan en un análisis cuantitativo y deben tomarse con precaución, encajan con la idea de una valencia positiva). A nivel gráfico, no se encontró relación entre el nivel de arousal generado y la calidad gráfica al jugar a los juegos Crysis y Dead Space [31]. Es importante reseñar que otra investigación anteriormente citada extraía conclusiones similares [9].

**Inmersión:** Las investigaciones indican que un aumento de la inmersión a nivel gráfico (con pantallas muy grandes, utilizando tecnología 3D o con gafas de realidad virtual) conlleva un aumento del arousal [32, 33], además de emociones como el miedo en juegos de terror [34]. Otro estudio indica que utilizar realidad virtual genera ansiedad [35], teorizando los autores que esto puede deberse al desconocimiento de dicha tecnología. Otros autores se han centrado en otras variables relacionadas con la inmersión. Se demostró así que el no usar auriculares genera más emociones negativas que llevarlos en un juego sangriento, aunque este efecto desaparece en otro tipo de juegos [36]. También los objetos tenidos en cuenta a la hora de diseñar un escenario parecen ser útiles para generar suspense (relacionada con mayor arousal y menor valencia y dominancia) y, por tanto, inmersión [37]. La propia presencia de una historia de fondo en el juego (frente a la posibilidad de un juego sin trasfondo) mostró un aumento de valencias positivas, aunque no de arousal [38]. Por último, la interactividad elevada como herramienta de inmersión es puesta a prueba en dos investigaciones. En la primera, se comprobó si usar movimientos de la cabeza en lugar de un joystick genera algún efecto emocional, encontrándose un aumento del arousal [39].



En la segunda, se concluyó que jugar con el Wiimote en lugar de con teclado y ratón (aumentando, por tanto, la interactividad) aumenta el arousal y la valencia [40].

**Eventos del juego:** se ha demostrado que los éxitos dentro del juego (sin importar el género) aumentan la excitación, mientras que los fallos generan frustración [41]. Aunque esto puede parecer obvio, esto da pie a analizar cómo los distintos cambios en dichos estados afectan a los individuos. Precisamente, un análisis de clustering sobre emociones en el juego Resident Evil [42] mostró que una gran multitud de eventos dentro del juego (muerte del jugador, aparición de enemigos, dificultad, argumento, cámara, atmósfera, etc.) provocan emociones negativas (preocupación, ira, miedo o asco, entre otras). Se ha encontrado que introducir la temática de la muerte en el juego como elemento existencialista genera una amplia variedad de emociones que varían según los jugadores [43]. Además, y siguiendo con las emociones que genera la temática de la muerte del personaje, se ha encontrado que las muertes aumentan el arousal, pero no alteran la valencia [44].

Por su parte, dos estudios han analizado las consecuencias de premiar o castigar conductas en videojuegos. Por un lado, premiar un evento positivo con una recompensa (conseguir puntos de experiencia, por ejemplo) genera una valencia positiva y un aumento del arousal [45]. Es interesante ver que esto también sucede con algunos eventos negativos, lo que va en consonancia con lo planteado por otras investigaciones previamente [25]. Por otro lado, premiar acciones violentas aumenta las emociones relacionadas con la hostilidad, así como la conducta agresiva dentro del mismo, en juegos violentos [46].

Por último, conviene destacar dos estudios que centran su atención sobre el tiempo de juego y la toma de decisiones, respectivamente. Por un lado, sus resultados indican que alterar un elemento como el tiempo de juego máximo en función de la habilidad del individuo no pareció afectar emocionalmente a los jugadores [47]. Por otro lado, comportarse de manera moral reduce la sensación de culpabilidad de los jugadores a la hora de tomar decisiones [48].

**Componente social:** el acto de jugar a videojuegos con más gente sirve para que se creen lazos entre dichos individuos [49], lo que genera un aumento de las emociones positivas (sea en población joven o más adulta). Jugar con un amigo genera un mayor arousal, mientras que la valencia se eleva si sabemos que estamos jugando con (o contra) un ser humano, y no una inteligencia artificial [50]. Por último, también se ha estudiado la contribución de los juegos competitivos a la generación de emociones violentas. Los resultados [51] plantean que el contenido del juego (por ejemplo, sangre o gritos realistas) contribuyen más a la generación de conductas agresivas que los juegos competitivos. Los juegos competitivos, de hecho, no generan

una mayor cantidad de emociones negativas, pero sí una sensibilidad hacia palabras positivas y negativas.

**Sonido:** diversos autores defienden que la música (y el contenido sonoro en general) afecta a las emociones generadas durante el uso de videojuegos [52]. Se han logrado relacionar las características de varias músicas de videojuegos, dividiéndolas por su excitabilidad (arousal) y placer (valencia). Precisamente por ello, los autores teorizan que la elección de la melodía en cada momento puede ser clave para transmitir la emoción adecuada [53]. Por último, los sonidos han demostrado también su utilidad para generar emociones. Se ha encontrado, por ejemplo, que el sonido de una respiración calmada y su paso a una respiración agitada puede generar un estrés en la persona que escucha [54].

**Contenido violento:** Como ya se ha apuntado anteriormente [51], el contenido violento en los juegos genera un aumento de las emociones negativas [55, 56] aunque no así la calidad gráfica [57]. Cuanto más realista es dicho contenido (por ejemplo, con sangre o gritos realistas), mayor sensación de arousal y afecto negativo [58]. A su vez, las emociones relacionadas con la agresión en videojuegos se relacionan con la frustración. Es precisamente creando una sensación de "incompetencia" en el jugador cuando se elevan las emociones agresivas, dado que sentir que no se es competente para superar una dificultad aumenta la frustración [59]. A mayor sensación de competencia, por tanto, menos agresividad. El contenido violento en juegos también puede generar un aumento del estrés, el cual puede ser detectado, por ejemplo, a través de la voz [60]. Por último, se encontró una elevación del arousal cuando hubo un evento de "búsqueda" de un jugador enemigo. Esto aumenta el arousal de ambos, hasta que se localizan. Sin embargo, con el tiempo se da una habituación que provoca que el enfrentamiento sea lo que genera arousal, y no la "cacería" [61].

#### IV. DISCUSIÓN

Como puede observarse en la presentación de los diversos resultados, la mayoría de los estudios suelen formar un corpus coherente en cuanto a sus resultados. Todos coinciden en afirmar que, de un modo u otro, existe una influencia emocional que se genera al provocar cambios en las características del juego. A su vez, la mayor parte de las conclusiones encontradas han resultado coherentes entre sí, lo que da fuerza a la idea de que la elicitación emocional en videojuegos puede resultar un campo especialmente útil para la industria, si se sabe qué se quiere generar y cómo hacerlo en cada momento.

Como puede inferirse de la tabla 1, la mayor parte de las investigaciones relativas a emociones y videojuegos se centran en el contenido violento, la inmersión del jugador y los eventos que suceden durante la partida. Si bien es cierto que estos conceptos pueden refinarse más (un nuevo estudio

podría proponer una taxonomía que categorizase todo), sí nos da una pista de cuáles son los campos más explotados por la investigación. Por el contrario, el sonido (incluyendo la música), el contenido social y los personajes (tanto jugadores como no jugadores) son los campos donde menos se ha profundizado.

También es llamativo el comprobar que las investigaciones no se centran en uno de los enfoques que se nombraban en la introducción, sino que parece haber una distribución equitativa de los mismos. Esto, unido a que las metodologías de extracción de información también son variadas (no hay una preeminencia de una concreta) puede influir en los resultados y en el modo de entenderlos. Futuras investigaciones deberían realizar una clasificación de los estudios previos, con el fin de categorizar las distintas perspectivas dentro de cada artículo.

Un patrón muy interesante planteado en algunas investigaciones [25, 45] es que muchas veces, ante un estímulo que debería generar una emoción negativa, los individuos responden de una manera positiva. Esto podría resultar especialmente útil si las investigaciones, en el futuro, logran determinar qué emociones negativas pueden llevar a provocar el efecto contrario en el individuo, generando un mayor interés en el juego para el jugador.

Por último, las nuevas propuestas de investigación deberían centrarse no solo en continuar analizando la elicitación emocional, sino estudiando el impacto que las distintas emociones tienen en la conducta del jugador dentro del juego y en las consecuencias que esto tiene para la experiencia de usuario percibida por el jugador. Del mismo modo que entender cómo funciona la elicitación, el conocer las consecuencias de los distintos estados emocionales (y cómo las diferencias individuales influyen en los mismos) puede ser útil, en un futuro, como medio de orientar a los diseñadores en la creación de videojuegos.

#### REFERENCIAS

- [1] E. Geslin, L. Jégou, & D. Beaudoin, "How color properties can be used to elicit emotions in video games", in *International Journal of Computer Games Technology*, 1. 2016.
- [2] I. Granic, A. Lobel, & R. C. Engels, "The benefits of playing video games", in *American psychologist*, 69 (1), 2014.
- [3] Global Games Market Report. *Newzoo Magazine*, 2016.
- [4] E. Hudlicka, "Affective computing for game design", in *Proceedings of the 4th Intl. North American Conference on Intelligent Games and Simulation*, pp. 5-12. 2008.
- [5] K. Gilleade, A. Dix, & J. Allanson, "Affective videogames and modes of affective gaming: assist me, challenge me, emote me", in *DiGRA 2005: Changing Views—Worlds in Play*. 2005.
- [6] F. Madeira, P. Arriaga, J. Adrião, R. Lopes, & C. Esteves, "Emotional gaming", in *Psychology of gaming*, pp. 11-29. 2013.
- [7] W. Wundt, "Grundrifi der Psychologie" [Outlines of psychology]. Leipzig, Germany: Engelmann. 1896.
- [8] P. Ekman, "An argument for basic emotions", in *Cognition & emotion*, 6 (3-4), pp. 169-200. 1992.
- [9] J. Banks, "Of beard physics and worldness: The (non-) effect of enhanced anthropomorphism on player–avatar relations", in *Psychology of Popular Media Culture*, 6(4), pp. 381. 2017.
- [10] S. F. Lin, "Gender differences and the effect of contextual features on game enjoyment and responses", in *Cyberpsychology, Behavior, and Social Networking*, 13(5), pp. 533-537. 2010.
- [11] M. Hofer, A. Hüsser, & S. Prabhu., "The effect of an avatar's emotional expressions on players' fear reactions: The mediating role of embodiment", in *Computers in Human Behavior*, 75, pp. 883-890. 2017.
- [12] A. M. Lokman, A. M. Mustafa, M. F. M. Fathir & A. R. A. Rahman, "Avatar warrior: A Kansei analysis", in *User Science and Engineering (i-USER) 3rd International Conference (IEEE)*, pp. 24-29. 2014.
- [13] C. C. Riddick, E. B. Drogin, & S. G. Spector, "The impact of videogame play on the emotional states of senior center participants", in *The Gerontologist*, 27(4), pp. 425-427. 1987.
- [14] A. Rodriguez, B. Rey, M. D. Vara, M. Wrzesien, M. Alcaniz, R. M. Banos, & D. Perez-Lopez, "A VR-based serious game for studying emotional regulation in adolescents", in *IEEE Computer graphics and applications*, 35(1), pp. 65-73. 2015.
- [15] B. Bontchev, & D. Vassileva, "Assessing engagement in an emotionally-adaptive applied game", in *Proceedings of the Fourth International Conference on Technological Ecosystems for Enhancing Multiculturality*, pp. 747-754. ACM. 2016.
- [16] D. Chen, J. James, F. S. Bao, C. Ling & T. Fan, "Relationship Between Video Game Events and Player Emotion Based on EEG", in *International Conference on Human-Computer Interaction*, pp. 377-384. Springer, Cham. 2016.
- [17] S. Nebel, M. Beege, S. Schneider, & G. D. Rey, "The higher the score, the higher the learning outcome? Heterogeneous impacts of leaderboards and choice within educational videogames", in *Computers in Human Behavior*, 65, pp. 391-401. 2016.
- [18] D. Giakoumis, D. Tzovaras, K. Moustakas, G. & Hassapis, "Automatic recognition of boredom in video games using novel biosignal moment-based features", in *IEEE Transactions on Affective Computing*, 2(3), pp. 119-133. 2011.
- [19] A. Mehrabian, & W. J. Wixen, "Preferences for individual video games as a function of their emotional effects on players", in *Journal of Applied Social Psychology*, 16(1), pp. 3-15. 1986.
- [20] N. Ravaja, M. Salminen, J. Holopainen, T. Saari, J. Laarni & A. Järvinen, "Emotional response patterns and sense of presence during video games: Potential criterion variables for game design", in *Proceedings of the third Nordic conference on Human-computer interaction*, pp. 339-347. ACM. 2004.
- [21] Y. Hasan, "Violent video games increase voice stress: An experimental study", in *Psychology of Popular Media Culture*, 6(1), pp. 74. 2017.
- [22] C. S. H. Yeh, "Exploring the effects of videogame play on creativity performance and emotional responses.", in *Computers in Human Behavior*, 53, pp. 396-407. 2015.
- [23] C. J. Ferguson, & S. M. Rueda, "The Hitman study: Violent video game exposure effects on aggressive behavior, hostile feelings, and depression", in *European Psychologist*, 15(2), pp. 99. 2010.
- [24] W. Bösche, "Violent video games prime both aggressive and positive cognitions", in *Journal of Media Psychology*, 22 (4), pp. 139. 2010.
- [25] L. Müller, S. Zagaria, A. Bernin, A. Amira., N. Ramzan, C. Grecos, & F. Vogt, "Emotionbike: a study of provoking emotions in cycling exergames", in *International Conference on Entertainment Computing*, pp. 155-168. Springer, Cham. 2015.
- [26] S. Roopchand-Martin, G. Nelson, C. Gordon & S. Y. Sing, "A pilot study using the XBOX Kinect for exercise conditioning in sedentary female university students", in *Technology and Health Care*, 23(3), pp. 275-283. 2015.
- [27] E. Geslin, L. Jégou, & D. Beaudoin, "How color properties can be used to elicit emotions in video games", in *International Journal of Computer Games Technology*, 1. 2016.
- [28] M. S. El-Nasr, "Projecting tension in virtual environments through lighting", in *Proceedings of the 2006 ACM SIGCHI international conference on Advances in computer entertainment technology*, pp. 63. ACM. 2006.



- [29] E. Joosten, G. Van Lankveld, & P. Spronck, "Colors and emotions in video games" in 11th International Conference on Intelligent Games and Simulation GAME-ON, pp. 61-65. 2010.
- [30] K. M. Reimer, & F. Khosmood, "Inducing Emotional Response in Interactive Media: A Pilot Study", in International Conference on Immersive Learning, pp. 122-131. Springer, Cham. 2016.
- [31] V. Ocasio-De Jesús, A. Kennedy, & D. Whittinghill, "Impact of graphical fidelity on physiological responses in virtual environments". in Proceedings of the 19th ACM Symposium on Virtual Reality Software and Technology, pp. 73-76. ACM. 2013.
- [32] S. H. Janicke, & A. Ellis. "The psychology of the 3D experience". in Stereoscopic Displays and Applications XXIV, 8648, pp. 86480. International Society for Optics and Photonics. 2013.
- [33] S. Bouchard, F. Bernier, E. Boivin, T. Guitard, M. Laforest, S. Dumoulin, & G. Robillard "Modes of immersion and stress induced by commercial (off-the-shelf) 3D games" in The Journal of Defense Modeling and Simulation, 11(4), pp. 339-352. 2014.
- [34] M. C. Jiménez, A. M. James, M. A. G. Maureira & I. Kniestedt, I, "Dreadful Virtualities: A Comparative Case Study of Player Responses to a Horror Game in Virtual Reality and Flat Screen", in International Conference on Advances in Computer Entertainment, pp. 239-260. Springer, Cham. 2017.
- [35] F. Pallavicini, A. Ferrari, A. Zini, G. Garcea, A. Zancacchi, G. Barone & F. Mantovani, "What Distinguishes a Traditional Gaming Experience from One in Virtual Reality? An Exploratory Study", in International Conference on Applied Human Factors and Ergonomics, pp. 225-231. Springer, Cham. 2017.
- [36] K. Riddle, Z. Di, S. Kim, E. Myung, S. K. Tay & F. Xu, "The unexpected comfort of wearing headphones: Emotional and cognitive effects of headphone use when playing a bloody video game", in Entertainment Computing, 19, pp. 43-52. 2017.
- [37] P. Delatorre, C. León, C., P. Gervás, & M. Palomo-Duarte "A computational model of the cognitive impact of decorative elements on the perception of suspense", in Connection Science, 29 (4), pp. 295-331. 2017.
- [38] E. F. Schneider, A. Lang, M. Shin, & S. D. Bradley "Death with a story: How story impacts emotional, motivational, and physiological responses to first-person shooter video games", in Human communication research, 30(3), pp. 361-375. 2004.
- [39] M. Ilves, Y. Gizatdinova, V. Surakka, & E. Vankka, "Head movement and facial expressions as game input" in Entertainment Computing, 5(3), pp. 147-156. 2014.
- [40] Y. S. Chen, "Emotion management and highly interactivity video games: Examining Emotion change in relation to arousal, involvement, and enjoyment". USA: *The Florida State University. Retrieved from ProQuest Digital Dissertations*. 2010.
- [41] D. Chen, J. James, F. S. Bao, C. Ling, & T. Fan, "Relationship Between Video Game Events and Player Emotion Based on EEG", in International Conference on Human-Computer Interaction (pp. 377-384). Springer, Cham. 2016.
- [42] H. W. Lin, P. Luarn, & Y. L. Lin, "Hierarchical Relationship of Negative Emotion Perception from Violent Video Games", in Science, Technology and Society, 22(2), pp. 236-258. 2017.
- [43] L. Chittaro, & R. Sioni, "Existential video games: Proposal and evaluation of an interactive reflection about death", in Entertainment Computing, 26, pp. 59-77. 2018.
- [44] T. McMahan, I. Parberry, & T. D. Parsons, "Evaluating player task engagement and arousal using electroencephalography", in Procedia Manufacturing, 3, pp. 2303-2310. 2015.
- [45] N. Ravaja, T. Saari, M. Salminen, J. Laarni, & K. Kallinen, "Phasic emotional reactions to video game events: A psychophysiological investigation", in Media Psychology, 8(4), pp. 343-367. 2006.
- [46] N. L. Carnagey & C. A. Anderson, "The effects of reward and punishment in violent video games on aggressive affect, cognition, and behavior", in Psychological science, 16(11), pp. 882-889. 2005.
- [47] A. Denisova & P. Cairns, "Adaptation in digital games: The effect of challenge adjustment on player performance and experience", in Proceedings of the 2015 Annual Symposium on Computer-Human Interaction in Play, pp. 97-101. ACM. 2015.
- [48] A. J. Weaver & N. Lewis, "Mirrored morality: An exploration of moral choice in video games", in Cyberpsychology, Behavior, and Social Networking, 15(11), 610-614. 2012.
- [49] S. Osmanovic & L. Pecchioni, "Beyond entertainment: motivations and outcomes of video game playing by older adults and their younger family members", in Games and Culture, 11(1-2), pp. 130-149. 2016.
- [50] N. Ravaja, T. Saari, ; Turpeinen, J. Laarni, M. Salminen & M. Kivikangas, "Spatial presence and emotions during video game playing: Does it matter with whom you play?" in Presence: Teleoperators and Virtual Environments, 15(4), pp. 381-392. 2006.
- [51] X. M. Zhang, M. Li, B. Yang & L. Chang, "Violent components and interactive mode of computer video game on player's negative social effect", in Intelligent Information Technology Application, 2009. IITA 2009. Third International Symposium, 3, pp. 95-103. IEEE. 2009.
- [52] K. Collins, "Making gamers cry: mirror neurons and embodied interaction with game sound", in Proceedings of the 6th audio mostly conference: a conference on interaction with sound, pp. 39-46. ACM. 2011.
- [53] M. Tsukamoto, M. Yamada & R. Yoneda, "A dimensional study on the emotion of musical pieces composed for video games", in Proceedings of 20th International Congress on Acoustics, 918. 2010.
- [54] J. Lauter, E. Mathukutty & B. Scott, "How can a video game cause panic attacks? 1. Effects of an auditory stressor on the human brainstem". in Proceedings of Meetings on Acoustics 158ASA, 8 (1) pp. 50001. ASA. 2009.
- [55] J. L. Whitaker, & B. J. Bushman, "Remain calm. Be kind. Effects of relaxing video games on aggressive and prosocial behavior". In Social Psychological and Personality Science, 3(1), pp. 88-92. 2012.
- [56] A. Melzer, I. Derks, J. Heydekorn, & G. Steffgen, "Click or strike: Realistic versus standard game controls in violent video games and their effects on aggression", in International Conference on Entertainment Computing, pp. 171-182. Springer, Berlin, Heidelberg. 2010.
- [57] D. Zendle, P. Cairns & D. Kudenko. "Higher Graphical Fidelity Decreases Players' Access to Aggressive Concepts in Violent Video Games", in Proceedings of the 2015 Annual Symposium on Computer-Human Interaction in Play (pp. 241-251). ACM. 2015.
- [58] E. J. Jeong, "Advertising Effects and Aggression in Video Games: Effects of Sensory Realism Cues on Brand Memory, Attitude, and Aggression Via Physiological Arousal, Affect, and Presence", in. Communication Arts and Sciences--Media and Information Studies. 2011.
- [59] A. K. Przybylski, E. L. Deci, C. S. Rigby & R. M. Ryan, "Competence-impeding electronic games and players' aggressive feelings, thoughts, and behaviors", in Journal of personality and social psychology, 106(3), pp. 441. 2014.
- [60] Y. Hasan, "Violent video games increase voice stress: An experimental study", in Psychology of Popular Media Culture, 6(1), pp. 74. 2017.
- [61] A. Lang, S. D. Bradley, E. F. Schneider, S. C. Kim, & S. Mayell, "Intra-Game Responses Meet the Necessary (But Not Sufficient) Theoretical Conditions for Influencing Aggressive Behavior", in Journal of Media Psychology, 24(4), pp. 154-165. 2012.

# Hacia la personalización de las aventuras culturales

Pedro A. González Calero

*Facultad de Informática*

*Universidad Complutense de Madrid*

Madrid, Spain

pedro@fdi.ucm.es

María Angeles Quiroga

*Facultad de Psicología*

*Universidad Complutense de Madrid*

Madrid, Spain

maquirog@ucm.es

Irene Camps

*Facultad de Ciencias de la Información*

*Universidad Complutense de Madrid*

Madrid, Spain

icamps@ucm.es

Pedro P. Gómez-Martín

*Facultad de Informática*

*Universidad Complutense de Madrid*

Madrid, Spain

pedrop@fdi.ucm.es

**Resumen**—El objetivo de este trabajo es sentar las bases que permitan generar juegos que se adapten a los jugadores. En particular, un tipo de juegos que hemos venido en llamar *aventuras culturales*, juegos de pistas en museos que sirven como vehículos de aprendizaje. El primer paso para ello es ser capaces de caracterizar qué tipos de actividades del juego son más adecuadas para cada tipo de niño. Dependiendo de cuestiones como la edad, el sexo, el estilo cognitivo y la capacidad. En este artículo describimos un juego de pistas en el Museo Nacional de Ciencias Naturales de Madrid, describimos cómo lo hemos instrumentalizado para recoger datos acerca de su uso y presentamos las primeras conclusiones que podrían servir de base a la generación de versiones personalizadas del juego.

**Index Terms**—personalización, juegos serios

## I. INTRODUCCIÓN

Los museos se enfrentan al reto de convertir con éxito su conocimiento y autoridad institucional en experiencias significativas y atractivas para audiencias heterogéneas. En ese sentido, en los últimos años hemos asistido a la proliferación de proyectos que aplican tecnologías digitales en el entorno físico del museo, incluyendo las aplicaciones de la realidad virtual, la realidad aumentada y distintas formas de gamificación [6][2].

El trabajo que aquí presentamos extiende trabajo previo en lo que hemos denominado “aventuras culturales”. Las aventuras culturales son básicamente juegos de pistas en dispositivos móviles que se desarrollan en instituciones culturales integrando elementos de reconocimiento de imágenes, realidad aumentada y virtual y que integran mecánicas de juego extraídas de las aventuras gráficas clásicas como la saga *Monkey Island* [3]. En ellas, el jugador vive una aventura virtual que le lleva a visitar distintos lugares e interactuar con diferentes personajes mientras va desentrañando una sucesión de enigmas. Una de las principales conclusiones que hemos sacado de analizar el uso de nuestras aventuras culturales es que la experiencia de los visitantes podría mejorar si fuésemos capaces de personalizar el juego en base a sus intereses, sus conocimientos previos o incluso su estilo cognitivo [1].

Financiado parcialmente por el Ministerio de Economía, Industria y Competitividad (TIN2017-87330-R)

El acceso personalizado a los contenidos es un reto no solo para nuestros juegos, sino que en esencia es un reto al que debe enfrentarse el museo moderno. El museo ha de comunicarse y hablar con un conjunto diverso de audiencias, desde el visitante casual, hasta el turista, el experto o el visitante recurrente. Los objetos de un museo cuentan muchas historias, y los conservadores sólo pueden colocar en las cartelas de las obras el contenido básico de interés para la mayoría de los visitantes. Al personalizarlos, lo que buscamos es que nuestros juegos cuenten una historia adecuada para ese visitante concreto en un momento dado.

La investigación en personalización de contenidos para juegos serios es un área incipiente que está ganando interés entre la comunidad científica en los últimos años. Una vez que se ha aceptado que los juegos digitales son un instrumento adecuado para otras aplicaciones más allá del puro entretenimiento, en formación y comunicación se está planteando la cuestión de cómo personalizar los juegos serios para aumentar su efectividad. En este sentido, encontramos trabajos que demuestran que la efectividad de los juegos serios mejora con la personalización y otros que avanzan en la definición de instrumentos para facilitar dicha personalización.

Dentro del primer grupo, en [4] se muestran los primeros resultados que confirman que personalizar las estrategias de un juego serio que promueve los hábitos saludables en base a la personalidad del jugador mejora su efectividad. Estos resultados preliminares fueron luego respaldados por un estudio empírico con más de 500 sujetos que efectivamente demuestra que la efectividad de las distintas estrategias usadas en el juego depende del tipo de jugador [5].

Por lo que se refiere al trabajo en instrumentos que faciliten la construcción de juegos personalizados, en [12] se avanza en la definición de un marco conceptual que permita alinear estilos de juego con mecánicas de juego, de forma que sea posible la personalización teniendo en cuenta características de su público objetivo. Aplicando estas ideas a los juegos serios, en [11] se describe un marco genérico para la personalización de los mismos donde se utilizan los elementos de los sistemas de recomendación para definir los aspectos personalizables en



un contexto de gamificación.

El trabajo que aquí presentamos es un primer paso en la búsqueda de un marco operacional que nos facilite la construcción de aventuras culturales personalizadas. En primer lugar, hemos instrumentalizado nuestros juegos para que recojan información sobre todos los aspectos relevantes de su uso. Esto nos permite llevar a cabo experimentos con usuarios a través de los cuales buscamos determinar los parámetros que mejor caracterizan la efectividad de nuestros juegos, y en base a ellos seleccionar las mecánicas de juego más adecuadas para cada tipo de jugador.

El resto del artículo está organizado de la siguiente forma. En el siguiente apartado describimos algunas ideas generales sobre estilos cognitivos y capacidades intelectuales que pueden afectar al uso del juego. En el apartado III se describe el juego que hemos desarrollado para el Museo Nacional de Ciencias Naturales de Madrid. En el apartado ?? se describe la instrumentalización que se ha hecho del juego para generar los datos necesarios para el experimento, descrito en el apartado IV. Finalmente en el apartado VI presentamos las conclusiones y el trabajo futuro.

## II. ESTILOS COGNITIVOS Y CAPACIDADES INTELLECTUALES

Los estilos cognitivos describen las diferencias individuales en los modos de conocer (percibir, atender, recordar, tomar decisiones [7]). Dan cuenta, por ejemplo, de por qué cuando estás escayolado ves muchas más personas escayoladas por la calle de lo habitual. En este ejemplo, la atención focal está guiada por los elementos internos de la persona (deseos, expectativas, preocupaciones) de modo que focaliza su atención en personas escayoladas (es como si resaltaran dentro del contexto).

Los estilos cognitivos describen por lo tanto diferencias cualitativas que están presentes tempranamente a lo largo del desarrollo (4-6 años). Esto implica que pueden valorarse ya en la infancia. Además son independientes de la capacidad intelectual.

Entre los estilos cognitivos más estudiados está el estilo cognitivo Reflexividad-Impulsividad descrito por J. Kogan [8]. Esta dimensión psicológica describe las diferencias en la forma de resolver problemas con ambigüedad en la respuesta. Es decir, problemas de comparación visual cuya solución no es evidente sino que requiere un proceso sistemático de formulación de hipótesis, chequeo, y finalmente respuesta. A modo de ejemplo, esto es lo que ocurre cuando has de buscar la figura que es igual al modelo, entre 6 alternativas posibles que difieren en uno o más aspectos del modelo. En la resolución de estos problemas se pueden observar 2 formas distintas de resolverlos: (1) Impulsiva: se echa un vistazo a las alternativas y se elige la aparentemente igual a partir de un detalle seleccionado (se tarda poco tiempo pero se comete muchos errores); (2) Reflexiva: se elige un detalle de la figura modelo y se chequean las demás descartando las que sean diferentes, con las que queda se chequea otro elemento de la figura y de nuevo se descartan las que difieren del modelo en

este aspecto; así se sigue hasta que sólo queda una alternativa posible (se tarda más tiempo pero no se cometen errores).

Además de estas dos maneras cualitativamente diferentes, se han identificado otras dos maneras de resolver estos problemas que difieren en capacidad: (1) lentos-inexactos, tardan mucho tiempo y aun así cometen muchos errores (el tiempo extra invertido no ayuda a resolver el problema) y (2) rápidos-exactos, son muy rápidos pero a pesar de ello apenas cometen errores (la rapidez en la respuesta no conlleva no haber contemplado las diversas alternativas sino que se basa en rapidez de procesamiento).

Las pruebas que componen nuestras aventuras culturales incluyen problemas que involucran diferentes capacidades intelectuales y es por ello que nos interesa establecer la relación entre dichas capacidades, la efectividad del juego y la satisfacción del jugador.

## III. EL JUEGO

El juego sobre el cual hemos realizado el experimento es un juego de pistas que se desarrolla en el Museo Nacional de Ciencias Naturales (MNCN) y pertenece a la saga Enigma Madrid<sup>1</sup>. Estos juegos han sido creados y desarrollados para jugarse de forma presencial en el Museo, ya que necesitan que la cámara del dispositivo móvil en que se juegan reconozca objetos del museo por lo que no es posible jugar a los mismos de forma remota.

La dinámica principal del juego es la búsqueda y reconocimiento de piezas. Las piezas han sido cuidadosamente seleccionadas para marcar el itinerario que se desea en la exposición “Evolución de la vida” en el MNCN, de manera que los usuarios deberán usar el juego en orden por las vitrinas, a la vez que observan la evolución de la vida en la Tierra. Su herramienta principal será una “paleolupa”, que no es más que la *tablet* del museo que usarán para reconocer las piezas que el juego les vaya solicitando.

La trama argumental explica que el grupo de la Doctora Anning, formado por la doctora y sus dos ayudantes, está buscando añadir un tercer ayudante al equipo y para ello se están llevando a cabo una serie de pruebas en el museo. La persona que juega adopta el rol de aprendiz de ayudante y tratará de conseguir unirse al equipo formado por Anning, Pérez y Neand, que se presentan en la Figura 1.

A modo de tutorial se pide al usuario que encuentre el cartel de la entrada en el que está dibujado Pérez, el perezoso con bata blanca. Una vez localizado el cartel, el juego invita a trasladarse hasta la zona de Paleontología donde comienza una búsqueda múltiple de tres objetos.

En la que se entiende como la primera prueba, a los usuarios se les facilita el nombre de los tres objetos a localizar (una *Brachiopoda Strophonema*, un *Calamopora Spongites* y una *Ammonitida Ammonitina Perisphinctidae*), y se les da una pista visual incluyendo el perfil de los objetos en la pantalla de búsqueda. En cualquier momento se les permite acceder a la ayuda, que vuelve a mostrar los nombres de las piezas, sin

<sup>1</sup><http://www.padaonegames.com/enigma/>



Figura 1. Personajes del juego

penalizarles por ello. En todo momento es posible rendirse en caso de no encontrar el objeto que se está buscando.

Cada vez que se encuentra una pieza, esta se registra en el diario de campo, una herramienta disponible en todo momento para que el jugador la consulte. El diario de campo, que se muestra en la Figura 2, será esencial en la siguiente prueba.



Figura 2. Página del Diario

Cuando el jugador ha encontrado las tres piezas deberá enfrentarse a una prueba verbal de conocimiento en forma de pregunta de respuesta múltiple cuya respuesta podrá encontrar en el diario de campo. En esta prueba se dispone de un tiempo limitado para responder a la pregunta. Si el tiempo se agota y no se ha escogido ninguna de las opciones esta prueba se dará por concluida con resultado erróneo. El diario de campo estará disponible durante la prueba y se registrará cada vez que el jugador la consulte. A partir de este momento, las pruebas que respondan a esta estructura las llamaremos pruebas de *quiz*.

La tercera prueba puede entenderse como una prueba en dos partes, primero se repetirá la estructura inicial de búsqueda guiada verbalmente, usando la *paleolupa*, esta vez sin apoyo visual de la silueta de la pieza, aunque sí se ofrece la posibilidad de consultar la ayuda para recordar el nombre del objeto a encontrar. Una vez encontrada dicha pieza se lanzará la segunda fase de la prueba. Rendirse también está a disposición del jugador y también lanzará la segunda parte de la prueba.

Esta fase consiste en un escenario 360° en el cual el usuario puede navegar utilizando un joystick electrónico que aparece en la pantalla, como se muestra en la Figura 3. El reto es encontrar los trilobites, que han sido reconstruidos y

emplazados en su medio natural, de esta manera se pretende que el usuario sea capaz de trasladar los fósiles encontrados al que se cree que fue su entorno. En esta segunda fase también existe la posibilidad de rendirse si no se encuentran los especímenes. Una vez finalizada esta fase se premiará al jugador con una nueva página del diario de campo. A este tipo de pruebas nos referiremos como “campos mágicos”.



Figura 3. Escena 360°

La cuarta vuelve a ser una prueba de quiz, esta prueba verbal de conocimiento es de mayor dificultad puesto que hace referencia a una página del diario que no se acaba de encontrar, sino a una encontrada en la primera prueba. De este modo se anima al jugador a utilizar la ayuda del diario de campo.

La quinta prueba también se compone de dos fases, la primera es una búsqueda verbal guiada, la segunda es un reto de habilidad: cazar a la Meganeura. Utilizando realidad aumentada en la cámara de la *tablet*, hacemos que un objeto virtual, es este caso una especie de libélula prehistórica llamada Meganeura, se mueva entre los árboles de un mural del museo, como se muestra en la Figura 4. El reto consiste en pulsar con el dedo sobre la imagen en movimiento, como si la cazáramos. A esta prueba nos referiremos como “meganeura”.

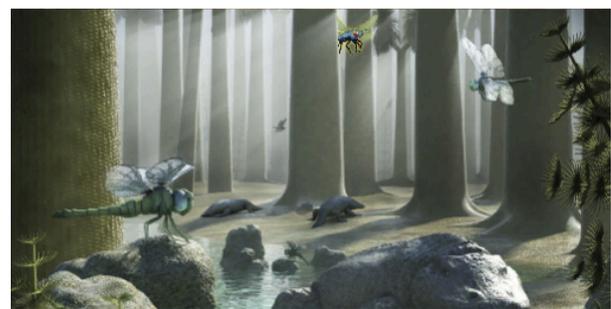


Figura 4. Meganeura

La sexta prueba es, de nuevo, una prueba en dos fases, la búsqueda guiada verbalmente usando la *paleolupa*, con su correspondiente ayuda disponible y la posibilidad de rendirse, que lanzará la siguiente fase igual que en la prueba anterior. A partir de este momento cada vez que la estructura se repita sólo se hará referencia a la misma como búsqueda guiada verbalmente.



En este caso, tras la búsqueda guiada verbalmente se iniciará un nuevo reto, se trata de lo que, de ahora en adelante, denominaremos *empaquetado*. La prueba consiste en 4 piezas que deben encajarse entre sí dentro de una caja, como se muestra en la Figura 5. Para este juego no hay opción de rendirse, si no consigues avanzar no podrás terminar con la aventura.



Figura 5. Empaquetado 4 piezas

La séptima prueba repite la búsqueda guiada verbalmente como primera fase y, como segunda fase repetimos de nuevo un empaquetado. De nuevo se dispone de 4 piezas que deben empaquetarse dentro de una caja simulando el trabajo que hacen los paleontólogos cuando mandan piezas a otros museos.

La octava prueba vuelve a ser un quiz, en esta ocasión sí preguntamos por conocimientos que se han obtenido en la etapa anterior.

La novena prueba está diseñada en dos fases, la primera es la conocida búsqueda visual con soporte verbal, pero la segunda no se había presentado hasta el momento. Se trata de una reconstrucción de un esqueleto, para ello el jugador dispone de piezas que están a la derecha y que podrá incluir en el esqueleto para completarlo, como se muestra en la Figura 6. Las piezas no sólo tienen que ubicarse en la posición correcta, además deben rotarse hasta obtener la rotación adecuada. Para apoyarse en la búsqueda del lugar de los huesos, el usuario dispone del modelo real en el museo, que le ayudará a determinar dónde pueden ir los huesos de los que dispone. A esta prueba nos referiremos como “esqueleto”.



Figura 6. Reconstrucción del esqueleto

La décima prueba enlaza con la octava en contenido pero en nada más, si bien el animal que se busca en ambas pruebas es el mismo en el primero se encuentra el esqueleto y en la segunda se busca su recreación visual en un mural del museo.

La décima prueba enlaza un reconocimiento visual guiado verbalmente con otro campo mágico en el cual el usuario puede navegar utilizando un joystick electrónico que aparece en la pantalla. El reto es encontrar, en este caso, un ictiosauro, en el escenario hay más de uno que han sido reconstruidos y emplazados en su medio natural, de esta manera se pretende que el usuario sea capaz de trasladar los fósiles encontrados al que se cree que fue su entorno. En esta segunda fase también existe la posibilidad de rendirse si no se encuentran los especímenes. Una vez finalizada esta fase se premiará al jugador con una nueva página del diario de campo.

Para terminar el juego se cierra con una undécima prueba, que vuelve a ser un quiz. En este caso se le pregunta al usuario por la página del diario obtenida en la prueba anterior.

Al final del juego, integrado en la propia aplicación, se lanza un cuestionario de satisfacción para que los usuarios puedan evaluar cuánto les ha gustado cada uno de los tipos de pruebas que han realizado durante el juego. Para que sea más claro qué prueba se está evaluando, se incluyen imágenes de cada una de ellas.

#### IV. DEFINICIÓN DEL EXPERIMENTO

##### IV-A. La muestra

Los grupos de niños y niñas que completan a la vez el juego constan de 10 a 14 participantes que juegan al juego hasta completarlo sin limitaciones de tiempo. La actividad se desarrolla en la parte del museo en la que está diseñado el juego. Pese a que no hay distracciones propias del museo, puesto que los experimentos se llevan a cabo cuando este está cerrado al público, los sujetos pueden verse afectados por el desempeño de sus compañeros u otros niños que se encuentran en el museo pero realizando otras actividades, así como por las madres o padres voluntarios que los acompañan o los educadores del museo. Esta vulnerabilidad a la distracción se verá reflejada en los tiempos que emplean para resolver las actividades del juego.

La muestra está formada por 30 sujetos con media de edad 9,4 años, (17 sujetos de 9 años y 13 de 10 años). De los 30 sujetos, 14 son chicos y 16 chicas. Se trata de una muestra homogénea puesto que todos acuden al mismo colegio donde cursan cuarto de primaria.

Todos los niños usaron, de manera individual, una tablet (Lenovo TAB3 10 Plus).

##### IV-B. Recogida de datos

Los datos se han recogido automáticamente instrumentalizando el juego con medidas del tiempo empleado en realizar cada una de las pruebas así como el resultado obtenido en ellas. Para ello, la aplicación se apoya en la conectividad de

las *tablets* del museo, que tienen acceso a internet a través de *Eduroam*<sup>2</sup>.

El *motor de ejecución* de la aplicación está jerarquizado de modo que, por ejemplo, cuando se lanza el juego se pone en marcha una aventura, que lanza, de manera secuencial, pruebas (apartado III), que lanzan, en orden, *etapas* (por ejemplo primero la búsqueda guiada verbalmente y luego el escenario 360°). Esa jerarquía se mantiene en la recogida de datos, de tal forma que se almacena una secuencia de métricas de cada prueba, y para cada una se guardan los datos de sus etapas. Toda la información se almacena internamente durante la ejecución, se *serializa* en formato JSON<sup>3</sup> y envía a un servidor.

La aplicación del servidor, desarrollada en NodeJS, almacena todas las métricas recibidas, enriqueciéndolas con información adicional como la marca de tiempo. Los datos crudos recopilados son procesados posteriormente para “*aplanarlos*” y reestructurarlos como un archivo csv de acuerdo a las necesidades particulares de las medidas experimentales.

## V. RESULTADOS

Debido a la escasa muestra de la que disponemos hasta el momento solamente realizaremos análisis descriptivos, los datos serán tratados con SPSS.

La satisfacción es una de las variables que más nos interesa analizar en profundidad. Esta variable contaba con tres valores pero la hemos dicotomizado para ganar potencia, se agrupan de la siguiente manera: “me ha gustado” (carita sonriente) y “no me ha gustado” (en la que se incluye carita triste y cara neutra). Hemos tratado de recoger la satisfacción de los usuarios preguntando por cada uno de los tipos de prueba que han realizado. Los resultados se presentan en la Figura 7 donde se muestra el porcentaje de niños que ha seleccionado “carita sonriente” para cada una de las herramientas.

Además, es interesante ver si existen diferencias entre las respuestas de satisfacción dependiendo del sexo de los participantes. Los resultados obtenidos se incluyen en la Figura 8.

Aunque por el momento las diferencias no son estadísticamente significativas, la tendencia observada muestra que a los chicos les gusta más la paleolupa, el empaquetado y los esqueletos mientras que a las chicas les gustan más las actividades meganeura y campo mágico. Este patrón diferente de satisfacción entre chicos y chicas muestra que los chicos prefieren actividades instrumentales mientras que las chicas prefieren actividades expresivas.

La satisfacción con el juego puede variar también según la edad. Pese a que nuestra muestra es bastante homogénea (9-10 años), hemos analizado si se observa algún patrón diferente entre los niños de 9 y los de 10 años. Para ello, de nuevo realizamos análisis descriptivos de tablas cruzadas y

<sup>2</sup>Eduroam (EDUCation ROAMing) es un servicio de *roaming* para investigadores, profesores y estudiantes que les proporciona acceso a internet cuando están en instituciones diferentes a las suyas (<https://www.eduroam.org/>).

<sup>3</sup>JavaScript Object Notation, un formato de intercambio de información jerárquica ligero, fácil de leer y escribir por humanos, y a la vez sencillo de interpretar y generar de forma automática.

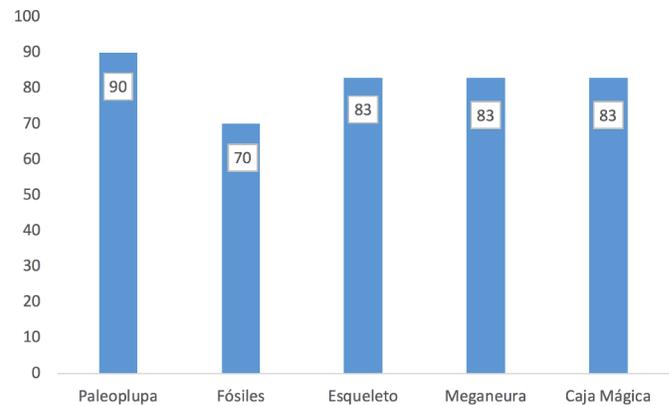


Figura 7. Porcentaje de satisfacción de cada tipo de actividad

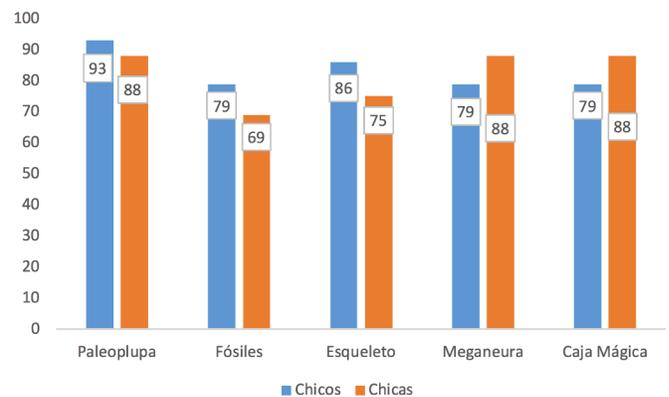


Figura 8. Porcentaje de satisfacción de cada tipo de actividad para cada sexo

los resultados, sin ser estadísticamente significativos, apuntan hacia una dirección: a los niños de 9 años les resultan más atractivos los juegos de menor complejidad y que más se repiten en el juego como son la paleolupa, que obtiene un 94 % de aceptación frente al 85 % que obtiene entre los niños de 10 años; o los campos mágicos, que obtienen un 94 % entre los de 9 años frente a un 69 % entre los de 10 años. Sin embargo, las pruebas con mayor dificultad como es la reconstrucción de los esqueletos que implican colocación y rotación de las piezas gustan más entre los niños de 10 años (85 % frente a 76 %). Estos datos apuntan a la necesidad de valorar la dificultad de cada juego por edad de modo que puedan configurarse combinaciones de juegos adecuados a cada una.

Otros aspectos interesantes que pueden influir en la satisfacción son tener la posibilidad de rendirse o de consultar la ayuda. En el primer caso, ninguno de los jugadores que consiguió completar el juego se rindió. Esto da a entender que rendirse es una acción no deseada que generaría insatisfacción, puesto en algunos casos el jugador estuvo más de 20 minutos buscando el fósil, hasta que lo encontró.



En el caso de la ayuda, dicotomizamos la variable “número de veces que se consulta la ayuda”, transformándola en “se consulta” o “no se consulta” la ayuda. Este análisis sólo puede realizarse en los problemas de búsqueda visual guiada verbalmente usando la *paleolupa*. En general, los niños han utilizado las ayudas en gran medida: 51 % en la segunda y tercera búsquedas, 78 % en la cuarta, 67 % en la quinta, 63 % en la sexta, 57 % en la séptima y 74 % en la octava.

Al relacionar la satisfacción global con el uso de ayudas a lo largo del juego, los resultados muestran que, de los 27 niños que puntuaron con un “me gusta mucho” la aplicación, la mitad (51 %) utilizaron ayudas en algún momento. Esto indica, que el uso de la ayuda se integra como parte del juego y no parece influir en la satisfacción de los usuarios. Por tanto, parece que la satisfacción no está relacionada de forma inversa con el uso de la ayuda. No obstante, de nuevo hemos de ser cautos dado el reducido tamaño muestral analizado.

## VI. CONCLUSIONES Y TRABAJO FUTURO

Hasta el momento se ha analizado el juego en un pequeño grupo ( $N = 30$ ) de niños de 9 y 10 años, en cuanto a la satisfacción que genera. Los resultados indican claramente que el juego en su conjunto ha gustado mucho tanto a los niños como a las niñas, en sus cinco componentes: paleolupa, empaquetado, esqueleto, meganeura y campo mágico.

Curiosamente, chicos y chicas tienen preferencias distintas en estas 5 actividades: los chicos prefieren las actividades más instrumentales (predominio de la acción) mientras que las chicas prefieren actividades más expresivas (predominio de la estética y la emoción). Es interesante que esta dimensión de diferenciación, evaluada habitualmente en adultos [10] pueda detectarse ya en la edad escolar. No obstante las actividades que prefieren las chicas también son menos complejas, por lo que en futuros trabajos habremos de considerar si a igualdad de capacidad, niños y niñas difieren en preferencias. Los resultados obtenidos por edad apuntan en la misma dirección: los de menor edad prefieren los juegos menos complejos.

En cualquier caso, el grupo analizado es muy pequeño y por tanto los resultados, siendo muy prometedores, han de tomarse con cautela.

En los próximos trabajos analizaremos la dificultad de cada juego para cada edad así como la posible incidencia del estilo cognitivo en la resolución de los problemas de búsqueda visual guiada verbalmente, como ya hemos hecho en trabajos previos [9].

A medida que avancemos en la comprensión de los distintos factores que afectan a la satisfacción seremos capaces de elaborar “itinerarios” por edad, como un primer paso hacia la personalización de nuestras aventuras culturales.

## REFERENCIAS

[1] Irene Camps-Ortueta et al. “Combining augmented reality with real maps to promote social interaction in treasure hunts”. In: *CoSECivi*. Vol. 1957. CEUR Workshop Proceedings. CEUR-WS.org, 2017, pp. 131–143.

[2] Panayiotis Koutsabasis. “Empirical Evaluations of Interactive Systems in Cultural Heritage: A Review”. In: *International Journal on Computational Methods in Heritage Science* 1.1 (2017), pp. 100–122.

[3] *Monkey Island*. Lucas Arts. San Francisco, CA, 1998.

[4] Rita Orji, Regan L. Mandryk y Julita Vassileva. “Improving the Efficacy of Games for Change Using Personalization Models”. En: *ACM Trans. Comput.-Hum. Interact.* 24.5 (2017), 32:1–32:22. DOI: 10.1145/3119929. URL: <http://doi.acm.org/10.1145/3119929>.

[5] Rita Orji, Gustavo Fortes Tondello y Lennart E. Nacke. “Personalizing Persuasive Strategies in Gameful Systems to Gamification User Types”. En: *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems, CHI 2018, Montreal, QC, Canada, April 21–26, 2018*. Ed. por Regan L. Mandryk y col. ACM, 2018, pág. 435. DOI: 10.1145/3173574.3174009. URL: <http://doi.acm.org/10.1145/3173574.3174009>.

[6] Ioannis Paliokas and Stella Sylaiou. “The use of serious games in museum visits and exhibitions: A systematic mapping study”. In: *8th International Conference on Games and Virtual Worlds for Serious Applications, VS-Games 2016*. 2016.

[7] M.A. Quiroga. “Diferencias individuales en la interrelación cognición-emoción: los estilos cognitivos”. En: *Psicología de la diversidad humana*. Ed. por J. Sánchez-Cánovas y M.P. Sánchez-López. Fundación Ramón Areces, 1999.

[8] M.A. Quiroga y J. Forteza. “La Reflexividad-Impulsividad: Estado de la cuestión y análisis de las características psicométricas del MFF20”. En: *Investigaciones Psicológicas* 5 (1988), págs. 97–124.

[9] M.A. Quiroga y col. “The Measurement of Intelligence in the XXI Century using Video Games”. En: *The Spanish Journal of Psychology* 19.e89 (2016), págs. 1–13.

[10] S. Sonja y T. Rigotti. “Instrumentality and Expressiveness at Work”. En: *Organisationspsychologie* 3 (2014), págs. 111–124.

[11] Gustavo Fortes Tondello, Rita Orji y Lennart E. Nacke. “Recommender Systems for Personalized Gamification”. En: *Adjunct Publication of the 25th Conference on User Modeling, Adaptation and Personalization, UMAP 2017, Bratislava, Slovakia, July 09 – 12, 2017*. Ed. por Mária Bieliková y col. ACM, 2017, págs. 425–430. ISBN: 978-1-4503-5067-9. DOI: 10.1145/3099023.3099114. URL: <http://doi.acm.org/10.1145/3099023.3099114>.

[12] Gustavo Fortes Tondello y col. “A Framework and Taxonomy of Videogame Playing Preferences”. En: *Proceedings of the Annual Symposium on Computer-Human Interaction in Play, CHI PLAY 2017, Amsterdam, The Netherlands, October 15–18, 2017*. Ed. por Ben A. M. Schouten y col. ACM, 2017, págs. 329–340. ISBN: 978-1-4503-4898-0. DOI: 10.1145/3116629.3116629. URL: <http://doi.acm.org/10.1145/3116629.3116629>.

# Retención de Usuarios en Videojuegos de Multijugador Masivo Aplicada al Ámbito Educativo

Jorge Osorio  
Narratech Laboratories  
Madrid, España  
jog989@gmail.com

Nahum Álvarez  
The National Institute of Advanced  
Industrial Science and Technology  
Tokio, Japón  
nahum.alvarez@aist.go.jp

Federico Peinado  
Ingeniería del Software e Inteligencia Artificial  
Universidad Complutense de Madrid  
Madrid, España  
email@federicopeinado.com

**Resumen**—Comparando las comunidades de jugadores localizadas en los videojuegos multijugador con las comunidades de alumnos que se dan en el ámbito educativo, podemos inferir paralelismos en las estructuras sociales de ambos sistemas propiciando la extrapolación a las aulas de los resultados de investigación realizada sobre videojuegos. Esta transferencia se plantea en este artículo a través de un plan integral de acciones para potenciar el rendimiento y el aprendizaje del alumnado, derivado de los métodos desarrollados en investigaciones previas cuyos objetivos eran potenciar la retención de los usuarios en comunidades específicas de videojuegos de multijugador masivo.

**Palabras clave**—Psicología Motivacional, Cibercomunidades, Diseño de Videojuegos, Videojuegos en Línea, Educación.

## I. MARCO TEÓRICO

En nuestro estudio sobre el comportamiento de los jugadores habituales de videojuegos [1] que resumimos aquí, se ha seleccionado un modelo conocido como la Teoría de la Autodeterminación de Ryan & Deci [2] (TAD de aquí en adelante). Este modelo se centra en analizar el contexto social y las condiciones particulares que se imponen a cada individuo, condiciones que potencian y facilitan, o por el contrario previenen y entorpecen, los procesos que llevan a la auto-motivación para permanecer o no activo en una plataforma de juego determinada. La TAD señala tres tipos de necesidades psicológicas innatas a la hora de actuar:

- Autonomía, el sujeto motivado siente voluntariedad.
- Competencia, el sujeto siente autoestima demostrando aptitudes respecto a la realización de una acción.
- Relación, el sujeto socializa satisfecho y seguro.

También se definen los factores de influencia relacionados con la necesidad, los cuales afectan al desarrollo de la conducta y pueden convertirse en motivaciones que refuerzan, frenan y en definitiva orientan de un modo determinado la aparición de la acción. Hay dos categorías:

- Intrínseca, la tendencia del sujeto a una acción por el simple placer de realizarla.
- Extrínseca, el permitir obtener resultados separables de la actividad motivada para obtenerlos.

El objetivo de nuestra investigación es obtener una base sobre la que mejorar el rendimiento académico promoviendo la necesidad de autonomía ya que, como nos enseñan los videojuegos, el grado de internalización de las motivaciones está

directamente relacionado con el nivel de autonomía percibida por el sujeto y a su vez genera por parte de éste un mayor compromiso con la acción, una efectividad comportamental superior, una mayor persistencia volitiva, un incremento del bienestar subjetivo del sujeto y una mejor asimilación del individuo dentro de su grupo social.

## II. METODOLOGÍA

Dado que la orientación para recabar datos se centra en la exploración y obtención de la mayor cantidad de información posible sobre el objeto de estudio, se decidió usar la entrevista en profundidad a jugadores habituales como método principal para el desarrollo del estudio. La estructura de análisis generada para ello tuvo como objetivo el registro, exposición y comprensión de los procesos conductuales motivados, los factores de influencia y los estilos que los regulan.

Para esta tarea se diseñó un protocolo de análisis basado en la TAD que fue aplicado sobre los discursos ofrecidos por los sujetos investigados [1]. Dicho protocolo de análisis motivacional se compuso de cinco fases: Localización de párrafos, Identificación de la necesidad predominante, Factores de influencia, Estilo regulatorio y Métodos derivados.

## III. RESULTADOS

Los resultados que obtuvimos de los experimentos usando nuestra metodología nos permiten obtener una descripción más precisa sobre las motivaciones que queremos fomentar, los factores de influencia con los que se relacionan y los métodos que los favorecen. A su vez, podemos planificar su adaptación en el ámbito educativo [1]. Los métodos adaptados mantienen su función original, pero están diseñados para alinearse con el contenido educativo, lo cual minimizaría una posible disrupción en la adquisición de conocimientos. Esto nos abre una nueva vía de experimentación que planeamos explorar para validar estos métodos en un trabajo futuro. Los métodos identificados en el estudio se detallan a continuación.

### A. Planificación de contenidos

Se trata de un método compuesto de varias estrategias para fomentar la retención y recaptación de jugadores. La extrapolación de este método al ámbito educativo por tanto buscará



la integración e implicación del alumnado, manteniendo su atención mediante el atractivo del contenido.

Desde los datos obtenidos derivamos las siguientes acciones para potenciar este método: Charlas de expertos en el campo de conocimiento, Excursiones culturales o Juegos colaborativos de corta duración. Con ello se evitarían las rutinas diarias excesivamente extendidas en el tiempo y el flujo de contenido se equilibraría de tal manera que la percepción de novedad no desaparecería o no tendería a reducirse.

#### B. Obras derivadas de otros productos culturales

Este método consiste en la creación de videojuegos en base a componentes relacionados con la cultura de masas.

Aplicado al campo de la docencia se propone como acción ofrecer un fuerte contraste entre el contenido teórico y la realidad actual a modo de gancho de atención para el alumnado. Consistiría en recabar información sobre temas de interés llevando el conocimiento que se pretende impartir hasta dichos temas. Con ello no sólo se conseguiría captar la atención si no que se mostraría la utilidad práctica del contenido impartido.

#### C. Sistemas de integración e implicación

Este método consiste en la aplicación de un conjunto de diseños orientados a potenciar el rendimiento a través de la integración en el grupo y la estabilidad del mismo.

La aplicación consiste en la generación de un ranking entre aulas de diferentes centros cuya valoración sea medida por el progreso global consistente en la suma del progreso de cada miembro. De ese modo se potencia la auto-percepción del usuario como miembro valioso además del sentimiento de valía en conjunto respecto a otras comunidades.

#### D. Sensación de libertad

Conocida técnicamente como ilusión de agencia, la sensación de libertad es una característica que figura como factor de atracción y retención en los análisis realizados.

La acción que se propone es que las actividades dentro de las aulas se basen en la ilusión de libertad ofreciendo cierto control de los grupos sobre el contenido a tratar, permitiéndoles elegir un tema de desarrollo, la posibilidad de realizar una investigación corta sobre la materia o la creación de una batería de debates a lo largo del curso que les hagan razonar las ideas y conocimientos de la asignatura.

#### E. Inmersión

Este mecanismo es frecuentemente utilizado por los jugadores y existe una relación proporcional entre la inmersión percibida por el sujeto y la evasión que obtiene jugando.

La extrapolación al ámbito educativo consistiría en ofrecer contenido no convencional durante el curso, cediendo en ocasiones la clase a expertos sobre la materia, planificando mesas redondas o visualizando documentales relacionados. Con ello buscaríamos la implicación de los sujetos con la materia cursada tratando de cambiar su actitud de oyente a participante o lo que es lo mismo de público pasivo a activo.

#### F. Orientador

La figura del orientador se documenta en los tres tipos de necesidad siendo un método muy recurrente y adaptable a diversas situaciones. En la aplicación al campo educativo se han seleccionado las tres funciones del orientador que mejor se adaptan para optimizar el rendimiento dentro de las aulas y potenciar la atención del alumnado:

- **Gestión:** El orientador debe encargarse de que cada alumno se integre en el grupo observando el entorno y previniendo la marginación de cada sujeto a través de la reorientación conductual y el asesoramiento personal.
- **Instrucción:** Cada orientador debe llevar sus esfuerzos a conseguir ser percibido más como un guía y un soporte que como una figura superior en términos de conocimientos pues tratamos de implicar al alumno con el contenido.
- **Mediación:** El orientador busca prevenir y solucionar los conflictos antes de que su gravedad aumente. Debe tomar medidas disciplinarias si se da la necesidad, ya que normalmente el conflicto empieza entre dos individuos o un grupo reducido de sujetos frente a un único individuo.

#### IV. CONCLUSIÓN

La flexibilidad que ofrece la TAD nos permite extrapolar los resultados de un campo de aplicación a otro. Tras ser aplicada a los videojuegos de multijugador masivo con resultados satisfactorios, éstos han sido fácilmente implementados al campo de la educación.

Este estudio motivacional ofrece ventajas en cuanto a pruebas de métodos dentro de los videojuegos por ser un entorno cerrado, medible y sobre todo controlable a niveles muy superiores si se compara con otros contextos para realizar trabajos de campo. El videojuego es comparable a un laboratorio pero con la peculiaridad de que se trata de un laboratorio social. De hecho llevamos varios años viendo cómo cobra cada vez más importancia el uso de las métricas obtenidas para optimizar la experiencia de los usuarios que interactúan con videojuegos.

Es posible que las reacciones de los sujetos no se den exactamente en la misma medida en los dos ámbitos, pero parece plausible aplicar un método que potencie la integración grupal en ambos, debidamente conectado en sus respectivas comunidades, una vez hemos comprobado que la estructura de sus conductas y sus necesidades son similares.

#### AGRADECIMIENTOS

Este trabajo se apoya en el proyecto ComunicArte, financiado por las Ayudas Fundación BBVA a Equipos de Investigación Científica 2017, y el proyecto NarraKit VR (PR41/17-21016), financiado por las Ayudas para la Financiación de Proyectos de Investigación Santander-UCM 2017.

#### REFERENCIAS

- [1] Osorio, J., Alvarez, N., Peinado, F. (2018). La retención de usuarios en los videojuegos con multijugador masivo: Una analogía entre las motivaciones sociales que influyen en el ámbito lúdico y educativo. Cuadernos de Información y Comunicación, 23. Madrid: UCM.
- [2] Ryan, R.M., & Deci, E.L. (2000). Self-Determination Theory and the Facilitation of Intrinsic Motivation, Social Development, and Well-Being. *American Psychologist*, 55, 1. pp. 68-78.

# Game Performance

## Cuestionamiento del videojuego como pieza cerrada e inalterable

Julio M. Álvarez-Bautista

Programa de Doctorado en Creación e Investigación en Arte Contemporáneo

Universidad de Vigo (UVIGO)

Vigo, España

artjulioalv@gmail.com

**Resumen**—Este artículo se centra en el universo artístico de los videojuegos y se dedica a analizar el potencial de los mismos como lienzo y herramienta y, a su vez, como obras artísticas y culturales que sitúan inevitablemente el concepto de pieza clásica en un lugar crítico, porque, a nuestro juicio, ponen en duda la representación tradicional, la autoría y la práctica, presentando sus razones, pruebas y fundamentos para expandir los dominios del arte.

Brevemente, las principales contribuciones del presente artículo son: (1) Comprender los videojuegos como piezas alejadas de la obra cerrada e inalterable, generando un nuevo paradigma, tanto de la obra como la figura del autor. (2) Engendrar una entidad nueva de creación y comunicación denominada *game performance*, suscitando metodologías paradigmáticas y herramientas para el desarrollo de videojuegos como de *performance art*. (3) Re-pensar el cuerpo, el tiempo y el espacio del jugador/*game performer*<sup>1</sup>. (4) Superar la falsa creencia de capturar y enlatar la experiencia efímera del jugador/*game performer*.

Por último nos gustaría señalar que el presente estudio suscita conclusiones y líneas de investigación futuras que esperan ser atendidas, exigiendo de otros proyectos de exploración para ampliar el conocimiento científico.

**Palabras clave**—*Game performance, game performer, avatar, híbrido, arte efímero.*

### I. INTRODUCCIÓN

El siglo XX ha girado en torno a restablecer la pieza clásica, por un lado, y, con más frecuencia, a su objeción a través de nuevas manifestaciones que ponen en duda la representación tradicional, la autoría y la práctica artística, presentando sus razones, pruebas y fundamentos para expandir los dominios del arte; contrariamente al enfrentamiento simplón que apoya o refuta la superación absoluta del objeto artístico que sigue las costumbres del pasado [1]. Un enfrentamiento excluyente que, a nuestro juicio, no favorece significativamente el siglo XX y el comienzo del nuevo siglo, dado que la aparición de novedosas tecnologías junto con la llegada de la era digital produce —entre

otras cosas— una migración hacia nuevos dispositivos, permitiendo a muchos artistas proponer proyectos desatendidos o censurados por parte del ecosistema del arte.

### II. LA LLEGADA DE LOS VIDEOJUEGOS

Para empezar es necesario aclarar que no se sabe con certeza cuál fue el primer videojuego de la historia, algunos consideran que fue *Cathode Ray Tube Amusement Device* (1947) de Thomas Goldsmith y Estle Ray Mann, otros opinan que fue *OXO* (1952) de Alexander Shafto Douglas, *Tennis for Two* (1958) de William Higinbotham, *Spacewar* (1962) de Steve Russell, *Odyssey* (1972) de la empresa Magnavox o *Pong* (1972) de la empresa Atari. Tampoco es nuestra intención e interés tomar una posición en este asunto, sin embargo el origen de los videojuegos es deudor de la época en la que floreció. Un contexto donde comienza a emplearse novedosas prácticas artísticas con posturas que rechazan la obra terminada y única, así como el gesto del creador; con la intención de ir más allá de las reglas y juicios tradicionales, propiciando la experimentación artística tanto en Europa como en Estados Unidos. Un lenguaje al margen de la estética típica que, con el paso del tiempo, fue presentado en la exposición internacional “documenta 5” de Kassel (1972); una exhibición especialmente controvertida que mostró un contexto determinado por diversas tendencias artísticas entre las que destacan el *realismo* y el *conceptualismo*.

En ese mismo ambiente surgen los videojuegos, siendo evidente que comparten —en cierto modo— características de sus predecesores, así como inéditas relaciones entre los artistas y el público; un espectador que ya no se limita a intervenir en la obra, sino que participa interactivamente en un paisaje artificial y computerizado.

Isaac López Redondo afirma que “la interacción es la característica que mejor define los videojuegos (...). Una implicación directa y de control que el videojuego ofrece, constituye quizás la característica fundamental y distintiva del medio” [2, pp.32-33]. Una propiedad que, a nuestra opinión, es

<sup>1</sup> El *game performer* es una persona o grupo de personas que ejecutan una acción artística sumergido/s en un videojuego. Existen múltiples diferencias entre jugador y *game performer*; sin embargo, la principal diferencia es ser conscientes del hecho artístico. Un suceso que cuestiona la representación predeterminada del videojuego, la autoría del mismo y la desacralización de la obra artística. El objetivo del *game performer*, entre muchos otros, no es superar la pieza, sino más bien extender sus dominios. Una postura que nos hace

re-pensar el propio cuerpo, tiempo y espacio del usuario, así como, entre otras cosas, superar la falsa creencia de capturar y enlatar la experiencia efímera del jugador/*game performer*. Una experiencia que trasciende los límites impuestos por parte de los medios de comunicación, las instituciones o incluso por la propia industria de videojuegos.



deudor de algunas manifestaciones de las vanguardias históricas, destacando la figura de Marcel Duchamp y Kazimir Malevich junto con los textos literarios del conde de Lautrèamont, Stéphane Mallarme, Antonin Artaud y Georges Bataille. Unas manifestaciones de vanguardia que insistieron –entre otras cosas– en la relación con el público para desechar los planteamientos tradicionales a favor de una renovación de conceptos. Un lenguaje interdisciplinar al margen de los criterios de la estética que sigue las costumbres del pasado; refinado, más tarde, por figuras como John Cage y Merce Cunningham, junto con el poeta Charles Olson y el artista Robert Rauschenberg, y demás figuras.

Resulta oportuno afirmar que la interacción en los videojuegos alude a un modo de conectar con una imagen. Una representación que espera ser *manipulada* por un sujeto, sin la intervención del usuario el propio videojuego perdería su propia ontología. El espacio virtual se convierte en otra cosa; un objeto perdurable en el tiempo, cerrado e inalterable, más cercano a la obra clásica y al artista como un ente especial. Una pieza artística mercantilizada afín a los medios de comunicación, la institución y la propia industria de los videojuegos e incluso a la captura y enlatado de la experiencia efímera propuesta por algunos usuarios o los eSports, por ejemplo. Unos archivos audiovisuales que no apresan completamente la experiencia que proporciona un videojuego –entendiendo ésta más allá de la estética–, como puede ser la admirable *muerte* que padece nuestro *cuerpo avatarial* en el videojuego *Journey* (2012) de la empresa Thatgamecompany; una *muerte* acentuada por el *hardware*, el cual nos recuerda mediante pequeñas pulsaciones como nuestro cuerpo virtual pierde poco a poco la *vida* mientras escalamos una montaña cubierta de nieve.

En consecuencia, nosotros proponemos superar la falsa creencia de capturar y enlatar la experiencia efímera del jugador/*game performer*, así como re-pensar el cuerpo, tiempo y espacio del mismo para engendrar una entidad nueva de creación y comunicación denominada *game performance*, suscitando metodologías paradigmáticas y herramientas para el desarrollo de videojuegos. Todo esto nos hace comprender los videojuegos como lienzo y herramienta artística y, a su vez, como obras artísticas y culturales que sitúan inevitablemente el concepto de objeto tradicional en un lugar crítico. Es decir, planteamos los videojuegos más próximos a su ontología que lo hacen ser un arte novedoso, sorprendente e innovador; una experiencia alternativa que proporciona un nuevo paradigma en la creación contemporánea, pero, para ello, debemos superar la falsa creencia que vincula lo virtual a la ausencia de existencia.

### III. EL CUERPO DEL AVATAR COMO ESPACIO HABITABLE

Superar la falsa creencia que vincula lo virtual a la ausencia de existencia, significa reorientar el debate hacia un lugar que permite nuevos campos de investigación y experimentación; y, al mismo tiempo, comprender un cuerpo que deja de ser concebido desde unos términos únicamente biológicos, ofreciendo la oportunidad de mejorar los límites de nuestra naturaleza que nos orienta a la subsiguiente etapa: el estadio posthumano [3].

En este sentido, los videojuegos anticipan una evolución de la especie humana; un *híbrido* entre el usuario y el avatar sin

implicar un enfrentamiento sangriento, es decir los videojuegos posibilitan la optimización y obtención de un *ente* realmente cibernético, por medio de una simbiosis positiva: la completa abstracción del cuerpo físico resultado de los procesos de inmersión que se producen en la mente del usuario para *habitar* un *cuerpo avatarial* sin necesidad de torturar nuestro cuerpo *real*, posibilitando estéticas y filosofías propias de una civilización mutante y en continua evolución.

El *cuerpo avatarial* integra al jugador en una situación de experimentación visual, edificando nuevas relaciones con la imagen. Significa entonces que se da, según Renaud [4], un nuevo tipo de corporeidad por medio de significaciones profundamente renovadas; una nueva materialidad que incluirá relaciones inéditas de *hibridación* y diálogo.

Inmersos en el cuerpo del avatar, habitamos un ecosistema en constante mutación, siendo capaces de poner en crisis el conocimiento que tenemos del tiempo, espacio y cuerpo que históricamente relacionamos a las propiedades trascendentales de los seres humanos, determinando un nuevo sujeto sin distinguir entre el organismo biológico y el circuito tecnológico en el que se encuentra sumergido. Un *híbrido* que desempeña un papel fundamental como presencia viva y soporte de creación, siendo evidente su relación con otras manifestaciones artísticas que emplean el cuerpo como lienzo y herramienta.

### IV. EL CUERPO COMO SOPORTE DE CREACIÓN

El empleo del cuerpo como lienzo y herramienta artística en un espacio y tiempo concreto es deudor de varias aportaciones creativas que conforman la *performance art*; un término general para una multitud de actividades, abarcando una amplia diversidad de estilos.

Tal y como ha sido entendido por la Historia del Arte, la *performance art* “son (...) acontecimientos efímeros cuya existencia como obra de arte tiene una duración siempre limitada (...). La acción puede ser una serie de controlados gestos íntimos (...) que pueden durar desde unos pocos minutos hasta muchas horas; puede presentarse sólo una vez o varias veces, con o sin guion, improvisando de manera espontánea o ensayando los gestos durante semanas o meses” [5, pp.7-8]. Unos movimientos que no ceden a los formalismos típicos, sino que la forma es una obra abierta, es decir la *performance art* es “un proceso, una obra inacabada, un ejercicio que te lleva a otro ejercicio para seguir abriendo puertas hacia otras experiencias” [6, p.55].

No obstante, ésta definición ha sido renovada debido a –entre otras cosas– la aparición de novedosas tecnologías junto con la llegada de la era digital, produciendo una migración hacia dispositivos con circuitos digitales para engendrar inéditos proyectos artísticos.

En otras palabras, los videojuegos restauran los conceptos trabajados en la *performance art* y otras manifestaciones artísticas, pero, al mismo tiempo, son obras artísticas y culturales que generan nuevas entidades de creación y comunicación junto con otras prácticas; una posible entidad la hemos denominado *game performance* que suscita metodologías paradigmáticas y herramientas para el desarrollo tanto de videojuegos como de *performance art*.

A nuestro juicio, la *game performance* comprende un *software* o *hardware* determinado; un término que no admite distintas lecturas y facilita, por consiguiente, inseguridad o desconcierto. Una modalidad artística que envuelve, se ajusta y se modifica cada vez que el *híbrido* cambia de gesto con cualquier parte del *cuerpo avatarial*, como podemos verlo en *LittleBigPlanet 3* (2017) del estudio británico Sumo Digital; un videojuego inspirador y profundamente creativo, donde podemos encarnar al avatar nombrado *Sackboy* y controlar la posición de los brazos, la expresión facial, las caderas o la cabeza del mismo para asentir o negar, así como modificar el espacio que envuelve al avatar por medio de la ubicación del *cuerpo avatarial* e incluso por la manipulación de los elementos que componen el espacio virtual. Evidentemente, unas posibilidades que hacen del videojuego un estupendo recurso para generar un suceso o varios hechos efímeros en distintos tramos temporales y espaciales.

También debemos señalar que el cuerpo de *Sackboy* es personalizable; a nuestro juicio, ésta posibilidad comprende el cuerpo como superficie, como lienzo; entendiendo nuestra materialidad *virtual* abierta a múltiples posibilidades.

#### V. UNA SITUACIÓN CRÍTICA PARA GENERAR DEBATE

Comprender el *cuerpo avatarial* e incluso el mundo virtual como utensilio o superficie donde generar arte son conceptos importantes alejados de la mercantilización de los videojuegos; un arte que no espera ser descrito con informaciones sesgadas, evaluado y clasificado por parte de la prensa.

Unos medios de comunicación que han desvirtuado el potencial del mundo *virtual*, limitando sus propiedades, así como las posibilidades creativas que tienen los jugadores. Unos usuarios que no son conscientes del hecho artístico; un suceso que extiende los dominios de la representación del videojuego, la autoría del mismo y la desacralización de la obra artística. Un acontecimiento que podemos experimentar, por ejemplo, en el videojuego *Pokémon Rojo* (1996) de la empresa japonesa Game Freak, donde el *game performer* consciente de sus propios actos y sus consecuencias en el juego electrónico genera diversos *glitches* para de-construir la estética y demás; un nuevo y sorprendente espacio *virtual* que *rompe y mezcla* todo el contenido del juego de vídeo con cada decisión que tome el usuario.

En sentido literal como en el metafórico, el videojuego es un arte vinculado a la vida, capaz de implicar a los espectadores dentro de la propia creación.

Sin embargo, como apunta Ana Gesto, “el cuerpo –en la *performance art*– no es el protagonista sino que es un elemento más, un material sin el cual la acción no sería posible” [7, p.93]; una sustancia íntimamente relacionada con el tiempo y el espacio; una materia que envuelve, se ajusta y se modifica cada vez que el *performer* cambia de gesto con cualquier parte del cuerpo [8]. Es decir, la estética en *Pokémon Rojo* (1996) se *parte y combina* con cada decisión del *game performer*, debido a que el usuario está *envuelto* en un tiempo y espacio específico; una materia que *cubre* al usuario y, a través del cual, éste puede *trasladarse y desenvolverse*; en otras palabras, el *game performer* no está frente a la obra, sino en la obra, nos *movemos dentro* de ella.

De todo esto se deduce que los videojuegos permiten a los espectadores una determinada experiencia creativa alejada de la propia *objetualidad*, impuesta, cada vez más, por parte de sus detractores y partidarios. Una situación crítica para generar debate en cuanto a las aportaciones creativas que generan los videojuegos.

Por último, es necesario hacer un inciso y aclarar que estas ideas no tienen como objetivo desvirtuar el potencial que suponen parte de los medios de comunicación e incluso parte de las instituciones o la propia industria de videojuegos, todo lo contrario. Nuestro objetivo es ampliar las fronteras que nos marcan para expandir los límites del arte.

#### VI. CONCLUSIÓN

Para finalizar es evidente que el concepto *game performance* surge como consecuencia de otras investigaciones que ponen el foco de atención sobre la *performance art* y cómo este espacio queda transformado a través de la interconexión con los dispositivos tecnológicos, como podemos ver en el estudio de *Digital Performance* (2007) de Steve Dixon, Nadja Linnine Masura en *Digital Theatre* (2007), Abuín González en *Teatro y nuevas tecnologías: conceptos básicos* (2008), Anna Maria Monteverdi en *Nuovi media, nuevo teatro* (2011), Zorita Aguirre en su tesis doctoral *La Experiencia perceptiva en la Performance Intermedial* (2016), Paola Belloni en el artículo *Teatro digital: ¿realidad o utopía? Nuevas tecnologías en el teatro español actual* (2016), entre muchos otros ejemplos.

A nuestro juicio consideramos que la *digital performance* –mencionada en el párrafo anterior– es una categoría muy amplia de la *performance art* que engloba, a su vez, múltiples modalidades; entre alguna de ellas se encuentra la *game performance*, la cual comprende un *software* o *hardware* determinado que la diferencia de las demás como la *video performance*, *photo performance*, *mobile performance*, *cyborg performance*... Una modalidad que afecta mutuamente los conceptos y resultados de los videojuegos y la *performance art*, redefiniendo las dos áreas.

En este sentido, la *game performance* comprende los videojuegos como piezas artísticas alejadas de la obra cerrada e inalterable, generando un nuevo paradigma, tanto de la obra como la figura del autor; es decir, los videojuegos son obras artísticas y culturales que no ceden a los formalismos tradicionales sino que la forma es una obra abierta, un proceso que abre puertas hacia otras experiencias.

Todo esto nos hace re-pensar el cuerpo, el tiempo y el espacio del jugador/*game performer*; un cuerpo posthumano –resultado de los procesos de inmersión que se producen en la mente del usuario– que desmantela el dualismo binario establecido en la cultura occidental para entender al ser humano como *híbrido* entre un organismo biológico y tecnológico. Un *híbrido* que escogerá entre muy diversas opciones un espacio concreto, resultando obvio que el progreso de la acción contendrá diferencias interesantes, en relación de si se tiene presente uno u otro espacio *virtual*; fijando, así, la actuación misma y estructurando tanto la percepción como la recepción del jugador.



Asimismo, el espacio *virtual* está dominado por el tiempo. Por un tiempo que va a haber que tomar en cuenta en el momento de articular un acontecimiento artístico. En este sentido, los videojuegos se identifican con la temporalidad; es decir, una obra artística y cultural dependiente de la noción del tiempo que tiene la posibilidad de intervenir de forma paralela con otros *híbridos* o consigo mismo. Una característica que ha suscitado la falsa creencia de capturar y enlazar la experiencia efímera del jugador/*game performer*; una experiencia que, a nuestro modo de ver, va más allá de lo puramente estético.

A manera de colofón, afirmamos que los videojuegos son un lienzo y herramienta y, a su vez, obras artísticas y culturales que sitúan inevitablemente el concepto de objeto artístico que sigue las costumbres del pasado en un lugar crítico, porque, a nuestro juicio, ponen en duda la representación tradicional, la autoría y la práctica artística con el objetivo de ir más allá de las reglas y juicios pretéritos.

#### AGRADECIMIENTOS

Nunca hubiera sido posible desarrollar el presente artículo sin el apoyo de mi director de tesis Carlos Tejo Veloso –profesor titular de la Universidad de Vigo– y mi codirector de tesis Antonio J. Fernández Leiva –profesor titular de la Universidad de Málaga– y, por otro lado, agradezco el apoyo incondicional de mis padres: María Rosario de los Ángeles Bautista Montero y Juan Manuel Álvarez Castro, y mi querida hermana: Rocío Alba Álvarez Bautista. Gracias.

#### REFERENCIAS

- [1] S. Marchán Fiz, *Del arte objetual al arte de concepto: epílogo sobre la sensibilidad «posmoderna»*. Madrid, España: Editorial Ediciones Akal, 1988.
- [2] I. López Redondo, *¿Qué es un videojuego? Claves para entender el mayor fenómeno cultural del siglo XXI*. Sevilla, España: Ediciones Héroes de Papel, 2014.
- [3] R. Iglesias García, *Arte y robótica: la tecnología como experimentación estética*. Madrid, España: Casimiro Libros, 2016.
- [4] A. Renaud. “Comprender la imagen hoy. Nuevas imágenes, nuevo régimen de lo visible, nuevo imaginario,” en *Videoculturas de fin de siglo*, J. Talens., Ed., Madrid, España: Ediciones Cátedra, 1990, (pp. 11-26).
- [5] S. Aznar Almazán, *El arte de acción*. Madrid, España: Editorial Nerea, 2000.
- [6] J. Seco Goñi, “Flujos conexos: la visión de un mirante,” en *10 x 10 + 1. acción!: performance en la Península Ibérica y territorios de ultramar*, J. Seco Goñi y Y. Pérez Herreras, Eds., Bizkaia, España: La Única Puerta a la Izquierda, 2011, pp. 53-84.
- [7] A. Gesto, “In pertinente, in esperando,” en *Châmalle 10: Una década de arte de acción*, C. Tejo, Ed., Galicia, España: Vicerreitorado do Campus de Pontevedra, 2013, pp. 93-96.
- [8] B. Ferrando, “Presentación,” en *10 x 10 + 1. acción!: performance en la Península Ibérica y territorios de ultramar*, J. Seco Goñi y Y. Pérez Herreras, Eds., Bizkaia, España: La Única Puerta a la Izquierda, 2011, pp. 7-12.



**V Congreso de la  
Sociedad Española para  
las Ciencias del  
Videojuego  
(V CoSECiVi)**

SESIÓN 2







# Generación Efectiva de Controladores Difusos Evolutivos para Carreras en Simuladores de Coches

Antonio M. Mora

Depto. de Teoría de la Señal, Telemática y Comunicaciones  
ETSIT-CITIC, Universidad de Granada, España  
amorag@ugr.es

Mohammed Salem

Department of Computer Sciences  
University of Mascara, Algeria  
salem@univ-mascara.dz

Juan J. Merelo

Depto. de Arquitectura y Tecnología de Computadores  
ETSIT-CITIC, Universidad de Granada, España  
jmerelo@ugr.es

Pablo García-Sánchez

Departamento de Informática  
Universidad de Cádiz, España  
pablo.garciasanchez@uca.es

**Resumen**—Los simuladores de carreras de coches han sido utilizados durante mucho tiempo como un entorno para probar algoritmos de control autónomo de vehículos. Constituyen un entorno en el que se evalúan todo tipo de algoritmos, incluyendo metaheurísticas, como por ejemplo Algoritmos Evolutivos. Sin embargo, el mayor desafío en este tipo de algoritmos evolutivos es diseñar un proceso de evaluación fiable y eficaz para los individuos, que se traducirá en la generación de buenas soluciones para el problema abordado: encontrar un controlador que sea capaz de ganar en una amplia gama de pistas y con distinto número de oponentes de diversa dificultad. Dicha evaluación no sólo implica el diseño de una función de aptitud (fitness) adecuada, que represente el nivel de calidad de los controladores de automóviles, sino también la selección de la mejor solución para la problema de optimización que se está resolviendo. Este paso puede resultar muy complejo, debido a la incertidumbre/ruido presente en el problema (condiciones meteorológicas y de la pista, comportamiento impredecible de otros conductores, etc). Por tanto, este trabajo presenta una serie de propuestas para realizar la evaluación de controladores difusos optimizados, analizando el rendimiento o calidad de los mismos en comparación con propuestas anteriores. Esto facilitará el diseño automático de un controlador autónomo para el simulador de carreras de coches TORCS. Para ello se parte de los resultados preliminares obtenidos en trabajos anteriores y se rediseña parte del procedimiento de evaluación del fitness. De modo que se estudian dos funciones de fitness diferentes en varios experimentos, junto con un novedoso enfoque basado en la competición para la selección del mejor individuo en cada generación.

**Index Terms**—simuladores de carreras de coches, TORCS, controladores difusos, conductores autónomos, algoritmos genéticos, optimización, evaluación

## I. INTRODUCCIÓN

La conducción autónoma es un problema que surge en muchos entornos, como los aviones, barcos, trenes o vehículos submarinos no tripulados. Recientemente están empezando a aparecer los primeros coches autónomos, en los que no es necesario un conductor humano. Todos estos sistemas se basan, en general, en una serie de entradas de sensores que incluyen velocidad real, obstáculos y otros vehículos. Considerando esas entradas, el controlador tendrá que tomar una decisión sobre la velocidad y dirección óptimas [7]. La

prueba de diferentes metodologías de conducción autónoma en el mundo real suele estar reservada a unas pocas empresas importantes, por lo que las pruebas de algoritmos se realizan normalmente en entornos simulados, los cuales ofrecen, a su vez, el incentivo de poder comparar mediante competiciones distintas propuestas.

En este artículo, utilizaremos *The Open Racing Car Simulator (TORCS)* [19], un simulador de carreras muy realista que proporciona un gran entorno de pruebas para la implementación y evaluación de conductores/controladores autónomos. TORCS ha sido utilizado en diversas ocasiones para la celebración de competiciones de Inteligencia Artificial (IA), donde el objetivo es crear los mejores pilotos autónomos de carreras [10]–[12]. Además de evaluar nuestros controladores enfrentándolos contra otros, el simulador puede ser utilizado como un entorno aislado para optimizar la conducción en una carrera en solitario.

Los Algoritmos Evolutivos (AEs) [1] han sido aplicados frecuentemente como un método de optimización de propósito general en este área, los cuales son habitualmente combinados con motores de comportamiento que gobiernan diferentes partes del coche [6], [15], [16] e incluso con aproximaciones basadas en Deep Learning [8]. Dichos motores de comportamiento han sido modelados recientemente mediante controladores difusos [4], [9], [14], los cuales aplican Lógica Difusa (*fuzzy logic* o FL en inglés) [2]. Dicha técnica es bastante adecuada para definir este tipo de agentes autónomos, ya que está inspirada en razonamientos que los humanos aplicamos al conducir. Un controlador difuso funciona con variables lingüísticas, y por ejemplo, girará *ligeramente* a la derecha cuando la siguiente curva esté cerca; si bien estos controladores tienen que ser diseñados para asociar apropiadamente las entradas a las salidas deseadas en situaciones específicas.

Los autores de este trabajo presentamos anteriormente una propuesta que combinaba dos controladores difusos especializados, diseñados a mano, que eran capaces de decidir el ángulo de giro adecuado del coche y la velocidad deseada en cada

punto (o en cada instante de juego, *tick*) durante una carrera [17]. Dicha propuesta fue revisada más tarde [18], optimizando los parámetros de sus funciones de pertenencia por medio de un Algoritmo Genético (AG) [3], mejorando el rendimiento del diseño manual, así como el de otros controladores de la literatura con los que se comparó.

Esto probó que los algoritmos evolutivos eran capaces de definir un conjunto de parámetros para el controlador difuso mucho mejor que los de un diseño hecho a mano, pero al mismo tiempo desveló varios desafíos. En general, los AEs optimizan la función de fitness que se utiliza, de modo que los controladores difusos evolucionados (en lo sucesivo, "FCs", o *Fuzzy Controllers*) serán finalmente tan buenos como lo permita dicha función. El problema es que en este caso no se puede considerar como función de aptitud la posición alcanzada por el FC en todas las carreras posibles en todas las pistas posibles y contra todos los oponentes posibles, así que tenemos que conformarnos con un *sustituto* de la función de fitness en un entorno muy limitado.

De modo que para mejorar el proceso de evaluación primero se optó por eliminar los oponentes, haciendo pruebas en carreras en solitario. Además se estudió qué factores relacionados con la velocidad, el daño y el tiempo por vuelta se deberían tener en cuenta para la evaluación de cada controlador (fueron incluidos en la función de fitness inicial).

Los resultados obtenidos en aquellos trabajos fueron alentadores, pero el modelo propuesto era algo "impreciso", ya que había que decidir cuál es la mejor pista para realizar el entrenamiento, así como los factores de carrera en solitario con mayor impacto en el rendimiento en una carrera real. En este sentido, en el presente estudio se ha elegido de forma analítica una pista concreta y representativa para los entrenamientos, la cual tiene una longitud media y combina tramos rectos con zonas de muchas curvas. A su vez se han combinado en la función de fitness, en dos aproximaciones distintas, los términos relacionados con la velocidad durante la carrera (a maximizar) y el daño recibido (a minimizar), que consideramos como los más relevantes. Además, se ha tenido en cuenta que el proceso de evaluación del fitness tiene un cierto grado de incertidumbre, como el hecho de que los daños y algunas condiciones de la pista pueden variar aleatoriamente en función del tipo de circuito. Por ello, en lugar de seleccionar directamente el mejor controlador en base a su valor de fitness como hicimos en los trabajos anteriores, en esta propuesta vamos a llevar a cabo una carrera entre los mejores individuos (controladores) para seleccionar al ganador.

El objetivo de estos tres factores (elección de pista, función de fitness y selección de ganador) es crear un algoritmo para crear controladores que sea más robusto y eficiente.

## II. EL SIMULADOR Y LOS CONTROLADORES

En esta sección se presentan el entorno de investigación considerado (el simulador de carreras de coches), y se describen los controladores definidos por los autores.

### II-A. *The Open Racing Car Simulator*

TORCS [19] es un simulador de carreras de coches de código abierto, realista, multijugador y modular que permite a los usuarios competir contra otros oponentes controlados por ordenador. Es un entorno de pruebas bastante fiable y muy utilizado en investigación en inteligencia artificial.

Cada coche en TORCS manejará un conjunto de sensores y valores del entorno, por ejemplo distancias a bordes de la pista o a otros vehículos rivales, el combustible restante, la marcha actual, la posición en la carrera, la velocidad, o los daños, entre otros. Estos valores serán considerados por los conductores autónomos o *controladores*, para gestionar el coche utilizando los llamados *actuadores*: giro del volante, acelerador, freno y cambios de marcha.

### II-B. *Subcontroladores Difusos*

El controlador diseñado por los autores se basa en el modelo de sensores y actuadores de la *Simulated Car Racing Competition* [12].

Sin embargo, la velocidad objetivo y el ángulo de giro de la dirección se calculan mediante dos sistemas modulares y especializados [17]. Estos subcontroladores incorporaron lógica difusa y consideran cinco sensores de posición. Partiendo de ellos, se aplicaron AGs para mejorarlos de manera automática.

El *subcontrolador difuso de velocidad objetivo* pretende estimar la velocidad objetivo óptima del coche, tanto en las partes rectas, como en las curvas de la pista. Para ello tiene en cuenta dos criterios: moverse lo más rápido posible y de la manera más segura (con el menor daño posible). Esta estimación se basa en dos casos generales: si el coche encara una línea recta, la velocidad objetivo tomará un valor máximo (*maxSpeed* km/h). Sin embargo, si está cerca de una curva, se disminuirá la velocidad actual a un valor incluido en el intervalo [*minSpeed*, *maxSpeed*] km/h.

Este controlador difuso tiene una salida, la velocidad, y tres valores de entrada (ver Figura 1):

- *Front* = Sensor\_9: Distancia frontal al borde de la pista (ángulo 0°).
- *M5* = max (Sensor\_8, Sensor\_10): distancia máxima al borde de la pista con un ángulo de +5°y -5°con respecto a *Front*.
- *M10* = max (Sensor\_7, Sensor\_11): distancia máxima al borde de la pista con un ángulo de +10°y -10°.

Se trata de un sistema difuso de tipo Mamdani [5] con tres funciones de pertenencia (MF) trapezoidales para cada variable de entrada. En [18] se optimizaron con un AG los conjuntos de parámetros que definen las funciones de pertenencia, mejorando en gran medida los resultados obtenidos.

Además, el controlador está basado en un conjunto de reglas difusas, diseñadas para maximizar la velocidad del coche dependiendo de las distancias detectadas al borde de la pista. Dichas reglas pueden verse en [17].

El segundo es el *subcontrolador difuso para el giro del volante*, que pretende determinar el mejor ángulo de giro en base a una estimación de la posición objetivo del coche. Su

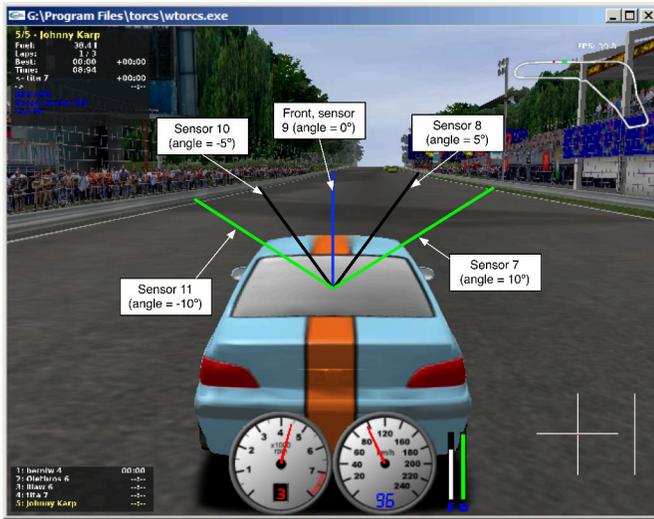


Figura 1. Sensores considerados de los 18 que tiene asociados cada coche en TORCS

estructura es similar a la del controlador anterior, basándose en los mismos sensores, pero considerando el giro como salida del mismo.

De modo que, como reglas generales: si el coche circula en línea recta, se fijará como posición objetivo el centro del carril por el que circula; mientras que, si el coche está cerca de una curva a derecha o izquierda, se acercará a la curva dejando un espacio entre el coche y el borde de la pista para evitar la pérdida de control.

Para detectar las curvas, el controlador revisa los valores de los sensores ( $M10$ ,  $M5$  y  $Front$ ), de modo que si el valor en el sensor frontal es el mayor, hay un tramo recto; mientras que si los valores de  $M5$  y  $M10$  con ángulos positivos (+5 y +10) son los mayores, habrá una curva a la derecha, y viceversa.

El controlador usa un conjunto de reglas que fue definido modelando el comportamiento de un conductor humano [17].

### III. ALGORITMO GENÉTICO

El algoritmo de optimización propuesto tiene como objetivo encontrar los parámetros óptimos de las funciones de pertenencia de los dos subcontroladores previamente introducidos.

El AG comienza creando una población inicial con valores aleatorios (distribución uniforme) para los parámetros en el rango definido  $[0, 100]$ . La idoneidad de cada solución candidata se calcula inyectando sus valores genéticos a los parámetros de las funciones de membresía de los dos subcontroladores difusos. El controlador autónomo definido se utiliza para conducir un coche en una carrera de 20 vueltas en un circuito sin oponentes en TORCS, y los resultados (velocidad máxima, mínima y media, junto con el daño obtenido) se utilizan para calcular el valor del fitness correspondiente.

Los controladores difusos tienen funciones de pertenencia trapezoidales, que siguen la Ecuación 1. En un controlador de este tipo, las reglas difusas se aplican a términos lingüísticos,

que califican las llamadas variables lingüísticas y que se definen mediante funciones de pertenencia que dependen de un conjunto de parámetros que determinan su forma y su ‘funcionamiento’. De modo que se aplicó un AG para optimizar dichos parámetros y determinar la partición difusa de la variable lingüística [20]. Las variables lingüísticas de entrada en nuestro problema serán  $Front$ ,  $M5$  y  $M10$ .

Una función de pertenencia (MF) trapezoidal, se define como:

$$\mu_A(x) = \begin{cases} \frac{x-x_1}{x_2-x_1}, & x_1 \leq x \leq x_2 \\ 1, & x_2 \leq x \leq x_3 \\ \frac{x_4-x}{x_4-x_3}, & x_3 \leq x \leq x_4 \\ 0, & \text{else} \end{cases} \quad (1)$$

with:

$$x_1 \leq x_2 \leq x_3 \leq x_4 \quad (2)$$

Como se puede ver, una MF está determinada por cuatro parámetros  $x_1$ ,  $x_2$ ,  $x_3$  y  $x_4$ , los cuales tienen valores en el intervalo  $[a, b]$  (Figura 2).

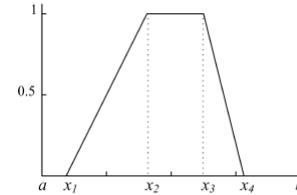


Figura 2. Función de pertenencia trapezoidal

De modo que una partición difusa con  $n$  MF trapezoidales se define mediante  $2n$  variables ( $a = x_1, x_2, \dots, x_{2n} = b$ ) (Ecuación 4). Con:

$$a = x_1 \leq x_2 \leq \dots \leq x_{2n-1} \leq x_{2n} = b \quad (3)$$

$$\mu_{A1}(x) = \begin{cases} 1, & x_1 \leq x \leq x_2 \\ \frac{x_3-x}{x_3-x_2}, & x_2 \leq x \leq x_3 \\ 0, & x > x_3 \end{cases}$$

$$\mu_{Ai}(x) = \begin{cases} 0, & x \leq x_{2i-2} \\ \frac{x-x_{2i-2}}{x_{2i-1}-x_{2i-2}}, & x_{2i-2} \leq x \leq x_{2i-1}, n = 2, \dots, i-1 \\ 1, & x_{2i-1} \leq x \leq x_{2i} \\ \frac{x_{2i+1}-x}{x_{2i+1}-x_{2i}}, & x_{2i} \leq x \leq x_{2i+1} \\ 0, & x > x_{2i+1} \end{cases}$$

$$\mu_{An}(x) = \begin{cases} 0, & x \leq x_{2n-2} \\ \frac{x-x_{2n-2}}{x_{2n-1}-x_{2n-2}}, & x_{2n-2} \leq x \leq x_{2n-1} \\ 1, & x > x_{2n-1} \end{cases} \quad (4)$$

Cuando el número de parámetros es reducido y sus rangos de variación están bien definidos, un AG con codificación binaria será suficiente para encontrar sus valores óptimos. Sin embargo, dado que en nuestro problema las salidas deseadas requieren precisión y el intervalo de variación de cada

parámetro no está bien determinado, hemos considerado una codificación real de los parámetros, que hemos dispuesto en un vector que incluye todas las variables a optimizar. De modo que cada individuo de nuestro AG será un vector con esa estructura, que tendrá 18 parámetros, 6 por variable.

La *inicialización de la población* de cromosomas/individuos se realiza asignando valores aleatorios en un rango de variación predefinido [3], a fin de comenzar la optimización desde un conjunto de valores prometedores [17].

Para llevar a cabo la evolución se han considerado: la selección de padres basada en *torneo*, un operador de *cruce aritmético simple en dos puntos* [21] y un operador de *mutación no uniforme* [13], por ser operadores genéticos bien contrastados en la literatura.

El objetivo principal del controlador autónomo en este entorno es ganar tantas carreras como sea posible. Sin embargo, tenemos que optimizar el caso más general mediante la realización de *carreras de entrenamiento en solitario*, que serán menos sensibles a la presencia de ruido/incertidumbre debido a la participación de otros controladores.

En propuestas anteriores nos enfocamos en la minimización del daño recibido (*damage*) y el tiempo de vuelta *LapTime*, a la par que intentábamos maximizar la velocidad máxima alcanzada *TopSpeed*. Sin embargo, en este estudio, nos hemos centrado en un "énfoque más humano", es decir, tratar de conducir lo más rápido posible en cada una de las partes de la pista evitando los daños. Por lo tanto, hemos considerado:

- Velocidad mínima (*MinSpeed*): para mejorar la conducción en zonas difíciles del circuito, como las zonas de curvas.
- Velocidad Máxima (*MaxSpeed*): para optimizar la conducción en las zonas rectas o sencillas de la pista.
- Velocidad Media (*AVGSpeed*): que modelará el comportamiento general en la pista.
- Daño (*Damage*): con el objetivo de crear controladores seguros, que sean capaces de terminar la carrera en cualquier circunstancia.

De modo que se han combinado estos factores en dos posibles funciones de evaluación/fitness:

GFC-MMS:

$$f_1 = \frac{(\text{MinSpeed} * \text{MaxSpeed})}{\text{Damage} + 1} \quad (5)$$

GFC-AVS:

$$f_2 = \frac{\text{AVGSpeed}}{\text{Damage} + 1} \quad (6)$$

Como se puede observar, en la primera función el objetivo es maximizar las velocidades mínima y máxima, a la par que se minimiza el daño recibido. En la segunda, se intenta maximizar la velocidad media del controlador en el circuito completo.

La evaluación de cada solución candidata (individuo) durante la evolución, haremos que cada uno de ellos compita en una carrera de entrenamiento de 20 vueltas en un circuito de dificultad media sin rivales. Como se ha dicho, hemos omitido la presencia de oponentes para evitar incluir fuentes de incertidumbre adicionales al proceso de optimización. Para

obtener controladores de comportamiento general, la pista seleccionada para este proceso tendrá una combinación de zonas de muchas curvas (difíciles) y partes rectas (sencillas).

Una vez que dicha carrera de prueba ha concluido, se tomarán los valores de salida: *Damage*, *MinSpeed*, *MaxSpeed* y *AVGSpeed* y se calculará el valor correspondiente del fitness aplicando la fórmula deseada.

#### IV. EXPERIMENTOS Y RESULTADOS

Después de analizar la mayoría de las pistas disponibles, hemos seleccionado para estos experimentos el circuito **Alpine 2**. Éste es bastante complejo, con múltiples tipos de curvas, aunque también con ciertas partes rectas (Ver Figura 3).

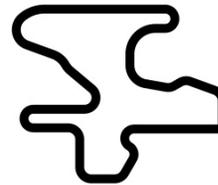


Figura 3. Circuito Alpine 2: Pista lenta de montaña. Longitud: 3773,57m, Anchura: 10m

Como coche para nuestro controlador, hemos utilizado *car1-ibr1*, ya que según experimentos anteriores [17], es la mejor opción debido a su rendimiento moderado y buen control, lo que lo hará adecuado para la gran mayoría de las pistas.

El controlador genético difuso (GFC) ha sido evaluado considerando las dos funciones de fitness propuestas: GFC-MMS (Ecuación 5) y GFC-AVS (Ecuación 6), comparando su rendimiento en carrera. Hemos ejecutado el algoritmo con una población de 50 individuos. El resto de parámetros son: Generaciones=50, Tasa de cruce=0,85, Tasa de mutación=0,1, y 10 ejecuciones diferentes por cada configuración.

Los dos procesos de optimización genética (uno por cada función de fitness) se han llevado a cabo de forma independiente. Sin embargo, a diferencia de trabajos anteriores en los que se seleccionaba el mejor en base a su valor para dicha función, en este estudio hemos buscado implementar una mejor metodología, la cual esperamos que produzca un controlador más competitivo.

Para ello, en ambas implementaciones, una vez finalizado el proceso evolutivo, los cuatro mejores individuos han competido juntos en 5 carreras (de 5 vueltas cada una) en la pista **Alpine 2** (utilizada durante la optimización) y 5 carreras (de 5 vueltas) en la pista **E-Track 5** (nueva para ellos).

Además, con el fin de mejorar la selección de los mejores, otros dos controladores son elegidos al azar para participar en la carrera, de entre una selección de bots de TORCS. Hemos implementado una competición basada puntos, que se basa en el esquema de la Fórmula 1, por lo que las puntuaciones obtenidas dependen de la posición del coche: 1 - 25 puntos, 2 - 18, 3 - 15, 4 - 12, 5 - 10, 6 - 8, 7 - 6, 8 - 4, 9 - 2, 10 - 1. Además, para incluir los términos de fitness en esta



selección, hemos definido una *puntuación extra*, de forma que el controlador que consiga el mejor tiempo o el daño mínimo en cada vuelta recibe 5 puntos extra.

Los resultados de estas ejecuciones se muestran en la Tabla I. Las "Mejores vueltas" "Daño mínimo" son las puntuaciones obtenidas por cada controlador en cada carrera al conseguir el mejor tiempo de vuelta y/o el daño mínimo de todos los contendientes. El símbolo '-' significa que el bot de TORCS no participa en la carrera.

Según la tabla, el primer individuo de  $GFC - MMS$  y el segundo de  $GFC - AVS$  han ganado el mismo número de carreras, pero  $GFC - AVS_2$  ha logrado mejores resultados en las carreras que no ganó. Hay que destacar que los resultados de los bots de TORCS no se han tenido en cuenta ya que sólo sirven para diversificar la selección y no participan en todas las carreras. Esta selección permite, por tanto, elegir el mejor individuo en varias carreras y de forma más robusta y estable, y así se evita la selección clásica por torneo donde se elige el ganador de una sola confrontación.

También se puede señalar que los controladores difusos genéticos obtienen el daño mínimo, incluso cuando no ganan la carrera. Este hecho justifica fuertemente el uso de daño en las funciones de fitness, que es un factor clave a tener en cuenta en las carreras reales (para terminarlas).

Los controladores obtenidos con la primera función de fitness también han sumado los puntos de las mejores vueltas en cinco de las diez carreras. Hay que tener en cuenta que la mejor vuelta es el resultado de un daño mínimo y una alta velocidad (*MaxSpeed*), ambos optimizados por dicha función de evaluación. En la misma línea, el segundo fitness intenta maximizar la velocidad media, pero no necesariamente *MaxSpeed*.

Para probar la efectividad del método, hemos elegido los dos mejores controladores difusos genéticos,  $GFC - MMS_1$  y  $GFC - AVS_2$ , uno por función de fitness, obtenidos en las pruebas anteriores. Éstos han sido evaluados en un conjunto de carreras contra algunos oponentes seleccionados. Además, los dos mejores controladores evolutivos de nuestro anterior trabajo [18], *EVO1* y *EVO2*, también han sido incluidos en la 'competición'.

Esta evaluación es un tipo de mini-campeonato, que también considera las puntuaciones de Fórmula 1, pero en este caso no hay puntos extra. Se realizaron 10 carreras, cada una de 20 vueltas, y con un total de 10 participantes por carrera: los dos mejores  $GFC - MMS_1$  y  $GFC - AVS_2$ , *EVO1*, *EVO2*, y también 6 bots competitivos de TORCS escogidos de la literatura. Las primeras 5 carreras se realizaron en la pista **Alpine 2** (usada en el entrenamiento); y las otras 5 carreras tuvieron lugar en la pista **E-Track 5** (no utilizada por los nuevos controladores, pero usada en la evolución de los anteriores). La parrilla de salida (posiciones iniciales de los coches) en estas carreras se estableció al azar.

Los resultados se muestran en la Tabla II. Esta tabla muestra cómo uno de los controladores difusos que evolucionan usando los nuevos mecanismos de selección y evaluación,  $GFC - MMS_2$ , da los mejores resultados, obteniendo muy

buenas clasificaciones en las carreras. El controlador Inferno1 también obtuvo muy buenos resultados, alcanzando 3 veces la mejor puntuación por vuelta, pero esos resultados están muy influenciados debido a que usó el coche más rápido. También podemos ver que nuestros dos controladores difusos genéticos sólo han ganado una carrera  $GFC - MMS_1$  y dos carreras  $GFC - AVS_2$ , mientras que los bots *berniw2* y *inferno1* han ganado tres carreras cada uno.

Sin embargo, como se puede ver en la tabla, aunque no son capaces de ganar siempre, sí que han terminado en posiciones altas de la clasificación, lo que les ha ayudado a obtener puntos y ganar el campeonato finalmente. De modo que la combinación entre la minimización de daño y la búsqueda de la velocidad media ha sido el mejor enfoque.

## V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo hemos presentado métodos para mejorar la generación efectiva de controladores para el simulador de coches TORCS mediante el uso de algoritmos evolutivos. Se parte de un controlador que hace uso de lógica difusa para calcular la velocidad objetivo (sub-controlador 1) y la dirección del coche (sub-controlador 2).

De modo que se han propuesto dos funciones de fitness más especializadas que las que usamos en trabajos anteriores [17], [18], enfocadas en la minimización de los daños obtenidos durante la carrera, así como la maximización de la velocidad máxima (en tramos sencillos), mínima (en tramos complejos) y media (en toda la pista).

Junto a esto, se ha postulado la selección heurística de pistas para el entrenamiento/evolución de los controladores, que contenga diversidad en sus tramos para obtener conductores autónomos más adaptables.

Además se ha propuesto un mecanismo de selección de los mejores controladores, una vez concluida la evolución, basándose en la realización de carreras y eligiendo al ganador en ellas, en lugar de ceñirnos al valor obtenido en la función de fitness. De este modo, se elegirá a los mejores de forma más justa y robusta.

Los experimentos realizados nos dejan clara la efectividad de las propuestas, puesto que se han enfrentado los controladores obtenidos contra rivales de nivel medio/alto, incluyendo los de trabajos anteriores de los autores, en un campeonato en el que han resultado ganadores los nuevos.

Como trabajo futuro, nos centraremos primeramente en la evaluación de los distintos enfoques aplicados, para identificar aquel que tiene mayor influencia en los resultados. Respecto al algoritmo genético empleado, se podría intentar implementar un enfoque multiobjetivo, que considere los distintos factores de la función de fitness como independientes.

## AGRADECIMIENTOS

Este trabajo ha sido financiado en parte por el Ministerio Español de Economía y Competitividad con los proyectos TIN2014-56494-C4-3-P (UGR-EPHEMECH), TIN2017-85727-C4-2-P (UGR-DeepBio) y TEC2015-68752 (también financiado por FEDER).



Tabla I  
PUNTUACIONES OBTENIDAS EN LA SELECCIÓN BASADA EN CARRERAS PARA LAS DOS IMPLEMENTACIONES EN DOS PISTAS DIFERENTES

Controlador	5 carreras en la pista Alpine 2 (5 vueltas cada una)							5 carreras en la pista E-Track 5 (5 vueltas cada una)							Total
	C1	C2	C3	C4	C5	Mejores vueltas	Daño mínimo	C1	C2	C3	C4	C5	Mejores vueltas	Daño mínimo	
<i>GFC - MMS<sub>1</sub></i>	25	18	8	15	12	15	10	12	25	18	25	18	10	10	221
<i>GFC - MMS<sub>2</sub></i>	12	25	15	12	15	0	5	8	15	15	4	10	0	0	136
<i>GFC - MMS<sub>3</sub></i>	6	6	10	10	8	0	0	15	10	10	18	6	0	5	104
<i>GFC - MMS<sub>4</sub></i>	2	8	4	4	6	0	0	10	1	2	1	2	0	0	40
<i>GFC - AVS<sub>1</sub></i>	1	4	6	2	4	0	0	4	2	12	10	4	0	0	49
<i>GFC - AVS<sub>2</sub></i>	15	10	18	25	18	5	10	25	18	25	15	15	5	10	206
<i>GFC - AVS<sub>3</sub></i>	10	2	1	6	2	0	0	2	6	4	6	1	0	0	41
<i>GFC - AVS<sub>4</sub></i>	4	1	2	1	1	0	0	1	4	8	2	8	0	0	32
<i>bt1</i>	-	-	-	8	-	0	0	-	8	6	8	-	0	0	-
<i>inferno1</i>	18	-	12	-	-	0	0	18	12	-	-	-	0	0	-
<i>berniw2</i>	8	15	-	18	-	0	0	-	-	-	12	12	5	0	-
<i>berniw3</i>	-	12	-	-	25	5	0	4	-	-	-	25	5	0	-
<i>damned1</i>	-	-	25	-	10	0	0	-	-	8	-	-	0	0	-

Tabla II  
RESULTADOS DEL MINI-CAMPEONATO CON 10 CONTROLADORES Y 10 CARRERAS EN DOS PISTAS DISTINTAS. tita,berniw E inferno SON CONTROLADORES INCLUIDOS CON EL SIMULADOR TORCS [19]

Controlador	Carreras en Alpine 2 (20 vueltas cada una)						Carreras en E-Track 5 (20 vueltas cada una)						Puntuación Total
	C1	C2	C3	C4	C5	Puntuación por pista	C6	C7	C8	C9	C10	Puntuación por pista	
<i>GFC - MMS<sub>1</sub></i>	25	10	18	12	10	75	18	12	15	15	12	72	147
<i>GFC - AVS<sub>2</sub></i>	15	18	25	15	15	88	25	18	18	12	18	91	179
<i>tita1</i>	4	2	1	2	2	11	4	2	1	4	6	17	28
<i>tita2</i>	2	1	2	1	1	7	1	1	2	1	2	9	16
<i>inferno1</i>	12	15	12	18	18	75	12	15	25	25	15	92	167
<i>inferno2</i>	10	12	4	10	25	61	10	10	4	2	8	34	95
<i>berniw1</i>	18	25	15	8	6	72	8	8	6	10	10	42	114
<i>berniw2</i>	8	8	10	25	12	63	15	25	10	8	25	83	146
<i>EVO1</i>	6	6	8	4	8	32	2	6	12	8	4	32	64
<i>EVO2</i>	1	4	6	6	4	21	6	4	8	6	2	26	47

## REFERENCIAS

- [1] T. Bäck, *Evolutionary algorithms in theory and practice*. Oxford University Press, 1996.
- [2] S. Godil, M. Shamim, S. Enam, and U. Qidwai, "Fuzzy logic: A 'simple' solution for complexities in neurosciences?" *Surg Neurol Int.*, pp. 2 – 24, 2011. [Online]. Available: <https://doi.org/10.4103/2152-7806.77177>
- [3] D. E. Goldberg, *Genetic Algorithms in search, optimization and machine learning*. Addison Wesley, 1989.
- [4] S. Guadarrama and R. Vazquez, "Tuning a fuzzy racing car by coevolution," in *Genetic and Evolving Systems, GEFS 2008*, March 2008. [Online]. Available: <https://doi.org/10.1109/GEFS.2008.4484568>
- [5] I. Iancu, *A Mamdani Type Fuzzy Logic Controller*. InTech, 2012, pp. 325–352.
- [6] T. S. Kim, J. C. Na, and K. J. Kim, "Optimization of an autonomous car controller using a self-adaptive evolutionary strategy," *International Journal of Advanced Robotic Systems*, vol. 9, no. 3, p. 73, 2012. [Online]. Available: <https://doi.org/10.5772/50848>
- [7] S. Kolski, D. Ferguson, C. Stacniss, and R. Siegwart, "Autonomous driving in dynamic environments," in *In Proceedings of the Workshop on Safe Navigation in Open and Dynamic Environments at the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Beijing, China, 2006.
- [8] J. Koutník, J. Schmidhuber, and F. Gomez, "Evolving deep unsupervised convolutional networks for vision-based reinforcement learning," in *Proceedings of the 2014 Annual Conference on Genetic and Evolutionary Computation*, ser. GECCO '14, 2014, pp. 541–548.
- [9] D. P. Liébana, G. Recio, Y. Sáez, and P. Isasi, "Evolving a fuzzy controller for a car racing competition," in *Proceedings of the 2009 IEEE Symposium on Computational Intelligence and Games, CIG 2009, Milano, Italy, 7-10 September, 2009*, 2009, pp. 263–270. [Online]. Available: <https://doi.org/10.1109/CIG.2009.5286467>
- [10] D. Loiacono, P.-L. Lanzi, J. Togelius, E. Onieva, D. A. Pelta, M. Butz, T. D. Lonnerker, L. Cardamone, D. Perez, Y. Saez, M. Preuss, and J. Quadflieg, "The 2009 simulated car racing championship," *IEEE Trans. Comput. Intell. AI Games*, vol. 2(2), pp. 131–147, 2010.
- [11] D. Loiacono, J. Togelius, P. L. Lanzi, L. Kinnaird-Heether, S. M. Lucas, M. Simmerman, D. Perez, R. G. Reynolds, and Y. Saez, "The wcc 2008 simulated car racing competition," in *2008 IEEE Symposium On Computational Intelligence and Games*, Dec 2008, pp. 119–126.
- [12] D. Loiacono, L. Cardamone, and P. L. Lanzi, "Simulated car racing championship: Competition software manual," *CoRR*, vol. abs/1304.1672, 2013. [Online]. Available: <http://arxiv.org/abs/1304.1672>
- [13] A. Neubauer, "A theoretical analysis of the non-uniform mutation operator for the modified genetic algorithm," in *Proceedings of the IEEE International Conference on Evolutionary Computation*, 1997. [Online]. Available: <https://doi.org/10.1109/ICEC.1997.592275>
- [14] E. Onieva, J. Alonso, J. Pérez, and V. Milanés, "Autonomous car fuzzy control modeled by iterative genetic algorithms," in *Fuzzy Systems*, 2009, pp. 1615 – 1620.
- [15] E. Onieva, D. Pelta, J. Godoy, V. Milanés, and J. Rastelli, "An evolutionary tuned driving system for virtual car racing games: The autopia driver," *International Journal of Intelligent Systems*, vol. 27, pp. 217–241, 2012.
- [16] E. Onieva, D. A. Pelta, J. Alonso, V. Milanés, and J. Pérez, "A modular parametric architecture for the torcs racing engine," in *Proceedings of the 5th IEEE Symposium on Computational Intelligence and Games (CIG'09)*. Piscataway, NJ, USA: IEEE Press, 2009, pp. 256–262.
- [17] M. Salem, A. M. Mora, J. J. Merelo, and P. García-Sánchez, "Driving in TORCS using modular fuzzy controllers," in *Applications of Evolutionary Computation. EvoApplications 2017, Lecture Notes in Computer Science, vol 10199*, S. K. Squillero G., Ed. Springer, Cham, 2017, pp. 361–376.
- [18] —, "Evolving a TORCS modular fuzzy driver using genetic algorithms," in *Applications of Evolutionary Computation. EvoApplications 2018, LNCS*, K. S. et al., Ed. Springer, 2018, p. To appear.
- [19] Sourceforge, "Web torcs," Web, Nov. 2016, <http://torcs.sourceforge.net/>.
- [20] H. D. Thang and J. M. Garibaldi, "A novel fuzzy inferring methodology for simulated car racing," in *IEEE International Conference on Fuzzy Systems, Hong Kong, China, 1-6 June, 2008, Proceedings*. IEEE, 2008, pp. 1907–1914. [Online]. Available: <https://doi.org/10.1109/FUZZY.2008.4630630>
- [21] S. G. Varun Kumar and R. Panneerselvam, "A study of crossover operators for genetic algorithms to solve VRP and its variants and new sinusoidal motion crossover operator," *International Journal of Computational Intelligence Research*, vol. 13 (7), pp. 1717–1733, 2017.



# A Machine Learning Approach to Predict the Winner in StarCraft based on Influence Maps\*

\*Summary of the paper with the same title published in Entertainment Computing 19 (2017) 29-41

Antonio A. Sánchez-Ruiz  
*Facultad de Informática*  
*Universidad Complutense de Madrid*  
 Madrid, Spain  
 antsanch@ucm.es

Maximiliano Miranda  
*Facultad de Informática*  
*Universidad Complutense de Madrid*  
 Madrid, Spain  
 m.miranda@ucm.es

**Abstract**—Real-Time Strategy games are very popular test beds for Artificial Intelligence (AI) researchers. In this work we try to predict the winner of StarCraft<sup>1</sup> games based on *influence maps*. Influence maps are numerical matrices representing the influence of each player's army in the map, and they are useful for different types of spatial reasoning. Our system reaches a level of precision similar to the human judges, although human judges base their predictions on a much more complex and abstract set of game features.

**Index Terms**—Real-Time Strategy Games, Influence Maps, Machine Learning, Prediction, StarCraft.

## I. INTRODUCTION

Real-Time Strategy (RTS) games are very popular test beds for Artificial Intelligence (AI) researchers because they provide complex and controlled environments on which to test different AI techniques [7]. In this work we try to predict the winner as soon as possible based on the events that occur in the game. This role of professional observer arises naturally in most traditional sports like football or even eSports where different experts analyze what is happening during the game and explain their opinions regarding the strategies selected by the players or teams.

We based our predictions on influence maps (IM), a spatial and tactical representation of the game state, and some standard machine learning classifiers. IM were initially used in the context of the game of Go [9] and have been more recently used in RTS games for pathfinding and reactive decision making [2], [4], [5], [8].

In order to test our approach, we use two different datasets of StarCraft games. The first one contains 4-player games in which all the players were controlled by the internal StarCraft AI. The second dataset contains real 2-player games from specialized websites. We have studied the precision of the predictions in different moments of the game, the number of games required to train the learning algorithms and the

stability of their predictions over time. Finally, we performed a small experiment to compare our results with the predictions made by some expert players and conclude that our results are comparable, but human experts base their predictions on a much more complex and abstract set of game features.

This paper is a brief summary of our previous work [6]. We encourage the interested reader to consult the original published version to fully understand the problem we try to solve, our approach and the results and conclusions.

## II. INFLUENCE MAPS

Influence maps (IM) represent the influence of the game units in the map as a numerical matrix or grid. IM are easy to compute and allow different types of spatial reasoning such as identifying boundaries and areas of control. IM can help to visualize and analyze the tactical deployment of troops in the map, a key factor in most strategy games.

The basic idea is that each unit exerts its influence in a nearby area and the numerical influence value in each tile depends on the distance to the unit and the strength (or value) of the unit. Map tiles under the influence of several units accumulate their influences, so that the more units a player concentrates in an area, the greater will be the values of influence in that part of the map.

Although in 2-player games it is possible to use only one IM to represent the strength of both players using positive numbers for one player and negative numbers for the other, in the general case we need a different IM for each player. StarCraft maps are already divided in logical tiles (96x96 is a medium map) but that level of detail would result in very big IM. Fortunately, IM are matrices that can be easily scaled to smaller sizes to represent the state of the game with the desired level of detail. In our experiments we scale each original influence map to a 4x4 matrix so we only need 16 variables to represent the state of each player in the game and we can use the same representation no matter the original size of the map.

This work has been partially supported by the Spanish Committee of Economy and Competitiveness (TIN2014-55006-R, TIN2017-87330-R) and the UCM (Group 921330).

<sup>1</sup><http://us.blizzard.com/en-us/games/sc/>

Expert	Precision (%)	Stable from (%)	Confident from (%)	Prec. AI DS (%)	Prec. Human DS (%)
Expert's average	72.22 (22.15)	41.43 (07.98)	67.38 (07.95)	76.46 (07.63)	67.99 (16.15)
SVM	70.37 (39.54)	21.67 (18.35)	NA	74.07 (23.13)	66.67 (57.74)
LDA	72.22 (26.06)	36.67 (26.58)	NA	66.67 (11.11)	77.78 (38.49)

TABLE I

RESULTS FROM THE EXPERIMENT WITH EXPERT PLAYERS. THE TABLE SHOWS AVERAGE VALUES AND STANDARD DEVIATIONS.

### III. GAME DATASETS

We used two different datasets of games. The first one contains 100 4-player games in which all the players were controlled by the internal StarCraft AI. These games were quite long, with an average duration of 72.5 minutes. We extracted the state of the game once every 30 seconds obtaining an average of 145 snapshots per game. The second dataset contains 200 2-player human games downloaded from BWreplays<sup>2</sup>, a website that collects games from several specialized websites. Humans play very differently from AIs and the average game duration was 12.5 minutes. In fact, in several games one player defeats the other one with basic combat units in a few minutes and there is not enough time to develop technologies or to expand to new locations.

In games with several players, the chances to win depend to a great extent on the interactions among the other players. For example, the first two players to engage in combat will probably lose several units while the other players keep their armies intact. Another example is that any player who suffers successive attacks from different opponents will not have many chances to survive. One peculiarity of the 2-Human player games was that 80% of the games ended early because one player left when he thought he had no opportunity to win. In those cases, we assigned the victory to the remaining player.

We obtained the best results using Linear Discriminant Analysis (LDA) [3] and Support Vector Machines (SVM) [1] with a polynomial kernel. In the first dataset (4-AI player games) we obtain an average precision of 66.62% but we need to wait until the last quarter of the game to predict the winner with precision over 80%. In the second dataset (2-Human player games) we obtain an average precision of 62.04% but we need to wait until the last tenth of the game to make a prediction with a precision of 80%. Human games are more challenging to predict (although there are only two players in the game) because of how fast one bad decision can unbalance the game.

### IV. EVALUATION WITH EXPERTS

How good is our system when we compare it with expert human judges? We organized a small experiment in which 14 experienced StarCraft players tried to guess who was going to win in 6 previously recorded games (3 from each dataset). The human judges were asked to decide the winner 9 times in each game (at 10%, 20%, ..., 90% of the game duration) and they could move the camera around the map while the game was paused for as long as they wanted (there was no *fog of war* so all the units were visible).

<sup>2</sup><http://bwreplays.com/>

Table I summarizes the results of the experiment. We show the results for the average of the 14 human judges and the 2 best classifiers. The columns represent the average precision and standard deviation, the moments of the game in which the predictions became stable and the experts felt confident, and the precision in each dataset.

We observed big differences among the participants in terms of precision (from 57.41% to 87.04%), but in average human judges obtained a precision of 72%, their predictions became stable at 41% of the game, and they feel confident about their prediction at 67% of the game. Our two best classifiers, SVM and LDA, obtained very competitive results and became stable much sooner than human judges.

### V. CONCLUSIONS

We conclude that it is possible to build machine learning classifiers based on influence maps that can compete with human experienced players in the task of predicting the outcome of StarCraft games.

During the debriefing at the end of the session, we learned that humans base their decisions on a much richer set of features that we are not able to capture with influence maps. In particular, human judges are able to anticipate and recognize high level strategies and they realize when one player makes a fatal decision. On the other hand, human judges found the minimap very useful and minimaps are similar to influence maps.

### REFERENCES

- [1] Corinna Cortes and Vladimir Vapnik. Support-Vector Networks. *Mach. Learn.*, 20(3):273–297, September 1995.
- [2] Holger Danielsiek, Raphael Stur, dAndreas Thom, Nicola Beume, Boris Naujoks, and Mike Preuss. Intelligent moving of groups in real-time strategy games. In Philip Hingston and Luigi Barone, editors, *CIG*, pages 71–78. IEEE, 2008.
- [3] R. A. Fisher. The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7(7):179–188, 1936.
- [4] Christopher E. Miles. *Co-evolving Real-time Strategy Game Players*. PhD thesis, Reno, NV, USA, 2007. AAI3274501.
- [5] Santiago Ontañón, Gabriel Synnaeve, Alberto Uriarte, Florian Richoux, David Churchill, and Mike Preuss. *RTS AI Problems and Techniques*, pages 1–12. Springer International Publishing, Cham, 2015.
- [6] Antonio A. Sánchez-Ruiz and Maximiliano Miranda. A machine learning approach to predict the winner in starcraft based on influence maps. *Entertainment Computing*, 19(Complete):29–41, 2017.
- [7] Jonathan Schaeffer. A Gamut of Games. *AI Magazine*, pages 29–46, 2001.
- [8] Alberto Uriarte and Santiago Ontañón. Kiting in rts games using influence maps. In *AIIDE*, 2012.
- [9] Albert L. Zobrist. A model of visual organization for the game of go. In *Proceedings of the May 14-16, 1969, Spring Joint Computer Conference*, AFIPS '69 (Spring), pages 103–112, New York, NY, USA, 1969. ACM.



# Implementación de generador estocástico de partidas mediante la configuración de dimensiones afectivas

José-Manuel Martínez-González  
*Escuela Superior de Ingeniería*  
*Universidad de Cádiz*  
 Puerto Real, España  
 jose.martinezgonzalez@alum.uca.es

Pablo García-Sánchez, Manuel Palomo-Duarte, Pablo Delatorre  
*Departamento de Ingeniería Informática*  
*Universidad de Cádiz*  
 Puerto Real, España  
 {pablo.garciasanchez,manuel.palomo,pablo.delatorre}@uca.es

**Resumen**—Enmarcados dentro del ocio interactivo, los videojuegos generan diversas emociones a sus jugadores. Este trabajo describe el diseño y desarrollo de un videojuego que construye en cada partida, de manera estocástica, diferentes versiones del universo narrativo en función de valores que el jugador asigna para las tres dimensiones afectivas: valencia, intensidad y control. Dichas dimensiones se han demostrado correlacionadas con el suspense narrativo evocado por las situaciones de la historia. Éste es medido como un factor entre un rango de valores que es empleado para observar la bondad del sistema. Para ello, se generan aleatoriamente mapas, detectando zonas jugables para incluir en ellas los diferentes elementos del entorno. Se tienen en cuenta el tamaño del mapa y las dimensiones referidas para obtener así una experiencia de juego personalizada en cada caso. La consideración de estas dimensiones implican modificaciones en varias características del juego: enemigos, recursos del protagonista, eventos del terreno y luz ambiental.

Se espera que este desarrollo sea la base para que futuros investigadores puedan realizar experimentos relacionados con la línea de investigación de la computación afectiva.

**Index Terms**—emoción, videojuegos, narrativa, suspense, computación afectiva

## I. INTRODUCCIÓN

Enmarcados dentro del ocio interactivo, los videojuegos generan miedo, alegría, odio o tristeza —de la misma forma en la que lo hacen las películas, las novelas y las series de televisión— mediante un discurso particular que permite evocar diferentes emociones a la audiencia [1]. Si bien la literatura científica contempla ya estos efectos emocionales desde el punto de vista de diferentes estrategias narrativas [2], dichos estudios se circunscriben a la percepción de los jugadores y, excepcionalmente, a la intención de los autores. Más allá de sus elementos estáticos en la trama y el entorno, los juegos actuales modulan típicamente la influencia emocional mediante la sencilla técnica de ajustar el nivel de dificultad, bien a criterio explícito o bien de forma automática, lo que afecta al control percibido sobre la situación y, en consecuencia, a la sensación de indefensión. Sin embargo, esto se considera

Este trabajo ha sido financiado en parte por el proyecto VISAIGLE (TIN2017-85797-R) financiado por la Agencia Estatal de Investigación (AEI) usando fondos ERDF; y los proyectos IDiLyCo (TIN2015-66655-R) y DeepBIO (TIN2017-85727-C4-2-P), financiados por el Ministerio de Economía, Industria y Competitividad, y los proyectos FEI InVITAR-IA (Universidad Complutense de Madrid) y SOL-201500054211-TRA (Universidad de Cádiz y Junta de Andalucía).

como una simplificación del impacto potencial que tendría si se favoreciera un mayor dinamismo en la intensidad de emociones. A este respecto, se observa en los desarrollos la carencia de una perspectiva cognitiva que clasifique y cuantifique los elementos del universo del juego respecto de su influencia afectiva, no habiéndose encontrado prototipos experimentales que exploten la interpretación del jugador con objeto de modular las emociones evocadas.

El objetivo de esta contribución es describir el diseño y desarrollo de un generador estocástico de partidas para un videojuego *first-person shooter* (FPS) el cual, mediante la parametrización de valores afectivos, generará un universo del juego específico con objeto de provocar un efecto emocional equivalente en el jugador.

Para ello y en primer lugar, en la Sección II se revisa el trabajo existente sobre las dimensiones afectivas y la generación de emociones en los videojuegos; a continuación, la Sección III presenta el diseño y desarrollo la implementación del videojuego y el generador estocástico, ilustrándose el resultado en la Sección IV; finalmente, en la Sección V se exponen las conclusiones y el trabajo futuro.

## II. TRABAJOS RELACIONADOS

Lejos de ser únicamente instrumentos de ocio, los videojuegos generan respuestas de diversa naturaleza en el jugador [3] [4]. Éstas se presentan en forma de emociones, evaluaciones cognitivas o motivaciones [5]. Existe una amplia literatura que analiza estos efectos [6], y que van desde la diversión [7] hasta el horror [8]. No obstante, estas propuestas no parecen contemplar el potencial del discurso del videojuego para evocar dinámica y automáticamente dichas respuestas. De esta forma, las técnicas observadas se circunscriben principalmente a la modificación de los niveles de dificultad [9].

Si bien se evidencia que la dificultad de la partida afecta a la capacidad de enfrentar los desafíos y, por tanto, a la emoción por la indefensión del personaje [10], existen otras dimensiones emocionales que apenas han sido tratadas explícitamente. Dichas dimensiones emocionales fueron estudiadas por Bradley et al. (1999) [11] en su estudio sobre normas afectivas asociadas a términos (ANEW), y son la valencia, la intensidad y el control. La valencia emocional  $V$  describe en qué grado un elemento causa una emoción placentera [12];

la intensidad  $A$  determina en qué grado un estímulo genera excitación [13]; por último, el control  $D$  refleja el dominio que un individuo siente, variando desde la falta total de control hasta el control absoluto [14].

En Delatorre et al. (2017) [15], dichas dimensiones emocionales fueron incluidas en una formulación –enunciada en la Ecuación 1– para la cuantificación del suspense narrativo, encontrándose una correlación de  $r = 0,8196$ ,  $p < 0,05$  entre el suspense estimado por la formulación y los valores reportados por el estudio ANEW. Sin embargo, este experimento se circunscribía a la evocación del suspense en sujetos espectadores, no jugadores.

$$\psi = f(V, A, D) = \frac{\Delta^{-1}V + \Delta A + \Delta^{-1}D}{\Delta_V V + \Delta_V A + \Delta_V D} \quad (1)$$

donde  $V$ ,  $A$  y  $D$  representan, respectivamente, valencia, intensidad y control. El operador  $\Delta$  obtiene la diferencia entre el valor actual y el más bajo posible en la escala de medida –valor 1, en los experimentos de Bradley et al. (1999)–;  $\Delta^{-1}$  obtiene la diferencia entre el valor más alto posible –valor 9– y el valor actual en la dimensión medida; y  $\Delta_V$ , obtiene la diferencia entre el valor más alto y más bajo posible. En consecuencia, la Ecuación 1 devuelve un valor más alto cuanto más baja es la valencia, más alta es la intensidad y más bajo es el control.

En este contexto, se pretende emplear el trabajo de Delatorre et al. (2017) como base para el diseño y desarrollo de un generador estocástico de partidas jugables, varias de cuyas características y restricciones dependen del valor parametrizado por el jugador para cada una de las tres dimensiones emocionales. Si bien el generador no está necesariamente orientado a entornos de suspense, se emplea el resultado de aplicar la Ecuación 1 como factor de evaluación, al ser la única valoración cuantitativa actualmente encontrada en la literatura.

### III. IMPLEMENTACIÓN

Desarrollado en Unity 3D<sup>1</sup>, el videojuego FPS construido para esta contribución propone al jugador la inmersión en un terreno boscoso compuesto por llanos y elevaciones, en el cual debe localizar una serie de cofres. Para ganar la partida, el jugador debe conseguir todos los cofres antes de que su energía se agote a causa de los ataques de los enemigos. Los cofres se distribuyen al azar por el mapa, en el que también se encuentran los enemigos, cuya tipología, predictibilidad y agresividad dependerá de los niveles de afectación emocional especificados. Dicha configuración también afecta a otros eventos del universo, por ejemplo, un árbol que cae cuando el personaje pasa cerca de él o un objeto que cambia bruscamente de lugar. Para ganar la partida, el jugador debe conseguir todos los cofres antes de que su energía se agote a causa de los ataques de los enemigos.

Para la creación de cada partida, en primer lugar el sistema genera un mapa compuesto por explanadas y montañas. A continuación, analiza el terreno para detectar las zonas

jugables del juego, en la que se ubicarán los diferentes elementos. Posteriormente y en función de los valores de afectación emocional en las tres dimensiones, se crean instancias de los diferentes elementos y se colocan en posiciones jugables tomadas al azar. Finalmente, se procede a dar el control al jugador para el comienzo de la partida.

A continuación, se detallan estos pasos.

#### III-A. Generación automática de terrenos

Para la construcción de terrenos se emplea una implementación de la ecuación de Perlin Noise para Unity3D [16]. Dicha aproximación proporciona valores pseudo-aleatorios óptimos cuando se trata de generar orografías realistas [17]. No obstante, la implementación de Unity3D devuelve valores que tienden a 1 y, por tanto, genera mapas como el que se muestra en la Figura 1. De esta manera y a pesar del realismo del terreno, éste carece de las partes lisas necesarias para insertar los elementos con los que interactuará el jugador.

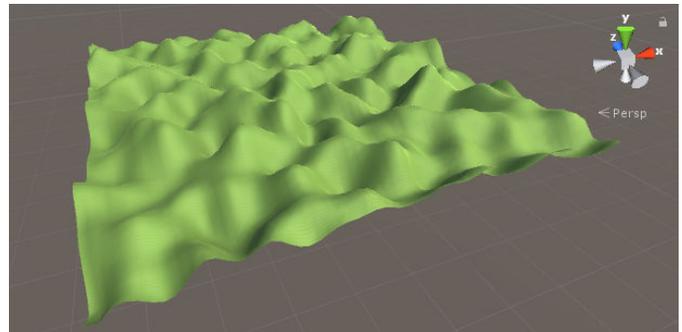


Figura 1: Terreno generado con ecuación de Perlin Noise

Para corregir esto, se modificó el algoritmo para controlar el nivel de ruido [18]. De esta forma se obtienen terrenos con zonas llanas manteniendo suficientemente el realismo deseado, como se ilustra en la Figura 2.

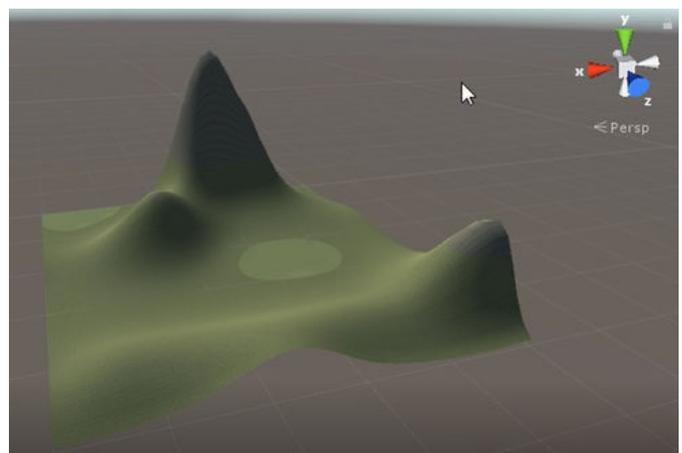


Figura 2: Terreno con ecuación de Perlin Noise modificada

En dicha Figura 2 se aprecia también la aplicación de texturas para permitir la diferenciación visual de las distintas alturas, siendo los niveles más bajos de color verde claro, el

<sup>1</sup><https://unity3d.com/es>



verde oscuro para las zonas entre las montañas y, el marrón, sobre las zonas montañosas por las que no es posible transitar.

En relación al tamaño del mapa, se han considerado tres posibilidades: pequeño, mediano y grande. Esto determina el número de árboles y cofres en escena, tal y como se reporta en la Tabla I.

	pequeño	mediano	grande
tamaño	257	513	1025
árboles	150	300	700
cofres	3	6	10

Tabla I: Número de árboles y cofres según el tamaño de mapa

### III-B. Detección de zonas jugables

Una zona se considera jugable si cumple con determinadas restricciones de altura, para lo cual se realiza un recorrido de las distintas zonas del mapa y marcando aquéllas que superan la restricción. A este respecto, se consideró un porcentaje óptimo de terreno jugable aquél que ocupaba el 60 % del mapa. La Figura 3 ilustra el resultado del proceso, mostrando en verde las zonas jugables y, en rojo, las no jugables.

### III-C. Inclusión de elementos en la partida

Mediante un menú previo a cada partida, el usuario debe escoger la configuración deseada en cuanto a tamaño de mapa y al valor de cada una de las tres dimensiones afectivas, como se muestra en la Figura 4. En ella se observa también el valor de suspense, resultado de aplicar la fórmula de la Ecuación 1.

Tras pulsar el botón 'GENERAR', da comienzo el proceso de generación del juego.

A partir de la primera población aleatoria de árboles y cofres declarados como elementos estáticos, Unity se encarga de generar una capa sobre el terreno sobre la que pueden desplazarse los personajes teniendo en cuenta los nuevos obstáculos existentes. A su vez, los personajes se conectarán al terreno mediante un componente *NavMesh Agent*. La Figura 5 muestra la capa generada.

Posteriormente se incluyen los personajes no-jugadores (NPC) y eventos, teniendo en cuenta el valor de las dimensiones afectivas. En concreto:

- **Caracterización relativa a la valencia**

La valencia representa la percepción positiva o negativa del estímulo. Así, las características relativas a la valencia se han relacionado con el tamaño y la gravedad de las posibles amenazas, siendo menores y más débiles cuando mayor es el valor de la dimensión. En el caso de valencia muy alta, los enemigos se sustituyen por animales pacíficos que interactuarán con el jugador

- **Caracterización relativa a la intensidad**

Se ha considerado que la intensidad emocional del jugador puede corresponderse potencialmente a la capacidad de ataque del personaje. De esta forma, la capacidad de su arma y la cantidad de munición es proporcional a la intensidad escogida.

- **Caracterización relativa al control**

La dimensión de control se relaciona con la indefensión del personaje, esto es, cuánto dominio percibe el jugador para salir exitoso de la partida. En consecuencia, cuanto mayor control se haya escogido, mayor cantidad de vida tendrá el jugador. Asimismo, se añade un minimapa si el valor de control supera la mitad de su valor. Dicho minimapa mostrará la ubicación de los cofres. En casos en los que el control se aproxime a su máximo, también mostrará la posición de los enemigos. Una imagen del minimapa puede observarse en la Figura 6.

- **Caracterización relativa al cómputo del suspense**

En esta versión, las interacciones entre las tres dimensiones se han simplificado a través del cálculo de la Ecuación 1. El suspense resultante se relaciona con aspectos del entorno y con la inclusión en la partida de una amenaza constante. Así, la luz ambiental se reduce proporcionalmente a este valor. De igual modo, cuando el nivel es muy elevado -es decir, en las situaciones extremas de muy baja valencia, muy alta intensidad y muy bajo control-, el sistema introduce a un enemigo especial que se moverá por el mapa en busca del personaje, finalizando la partida en caso de colisión con él. Asimismo, se incluyen eventos como árboles que caen u objetos que cambian de lugar.

La Tabla II resume los criterios referidos en este apartado.

## IV. EJEMPLOS DE ESCENARIOS GENERADOS

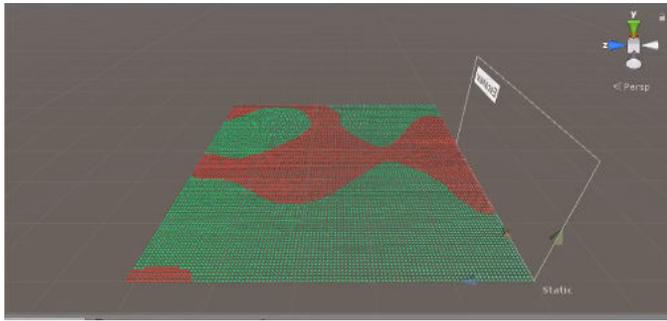
Las Figuras 7a, 7b y 8 ilustran algunos ejemplos generados con la aplicación.

En concreto, las Figuras 7a y 7b muestran una versión donde el nivel de intensidad es bajo, por lo que el jugador no tiene armas. Asimismo, el nivel de control es alto en ambos casos, mostrando el minimapa en la parte inferior. Sin embargo, en conjunto la partida generada en la Figura 7a tiene un mayor valor de suspense, lo que provoca una reducción de luz en el entorno.

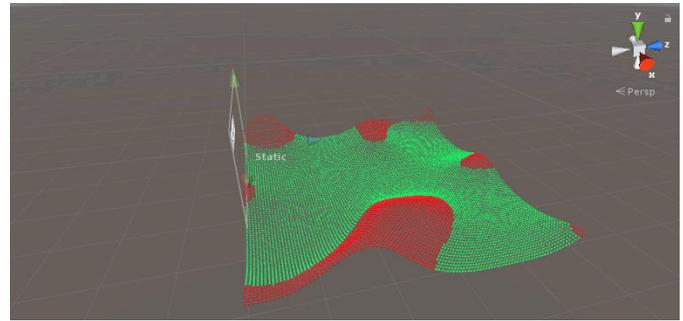
En contraposición, el escenario de la Figura 8 revela una pistola debido a que el nivel de intensidad se parametrizó a un valor entre 0.25 y 0.5. Al ser la dimensión de control menor de 0.5, se observa también la cantidad media de energía y la falta de minimapa. Finalmente, la valencia fue establecida al máximo, por lo que aparecen animales a lo largo del terreno. El valor de suspense, en el rango 0.25 a 0.5, aporta una luz ambiental alta.

## V. CONCLUSIONES

Este trabajo presenta el diseño y desarrollo de un videojuego FPS cuyas partidas son construidas de manera estocástica en función del valor de tres dimensiones emocionales: valencia, intensidad y control. Para ello, se ha descrito el proceso de generación aleatoria de los mapas mediante la ecuación modificada de Perlin Noise, la selección de las zonas jugables y la inclusión de los diferentes elementos del entorno, teniendo en cuenta el tamaño del mapa y las dimensiones referidas, y obteniendo así un juego distinto en cada generación. La consideración de estas dimensiones implican modificaciones



(a) Ilustración en dos dimensiones de zonas jugables



(b) Ilustración en tres dimensiones de zonas jugables

Figura 3: Ilustraciones de zonas jugables

	valencia	intensidad	control	suspense
[0, 0,25]	enemigos duros	sin arma	energía baja	luz máxima, sin eventos
(0,25, 0,5]	enemigos medios	pistola	energía media	luz alta, algunos eventos
(0,5, 0,75]	enemigos débiles	ballesta	energía alta, minimapa con cofres	luz media, varios eventos
(0,75, 1]	personajes inofensivos	bazoca	intocable, minimapa con cofres y enemigos	luz baja, muchos eventos, enemigo especial

Tabla II: Caracterización de los elementos por valor de las dimensiones emocionales



Figura 4: Menú de configuración de partida



Figura 6: Minimapa

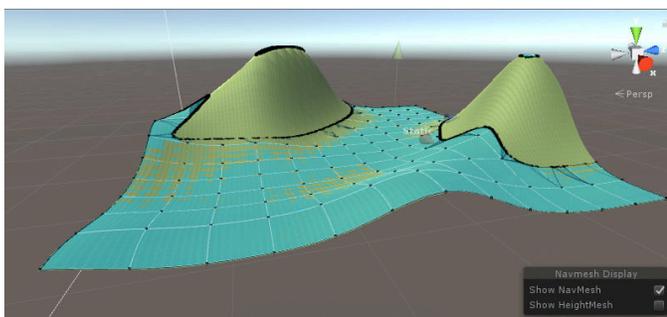


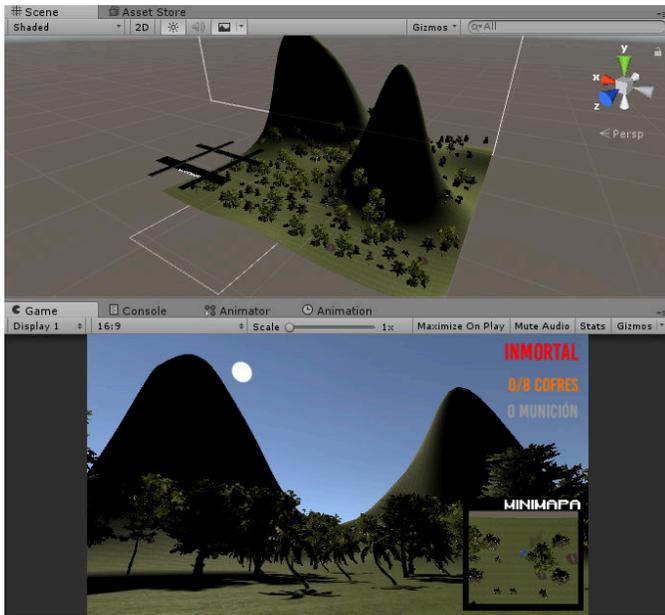
Figura 5: Mapa con zonas jugables calculadas

en varias características del juego: enemigos, recursos del protagonista, eventos del terreno y luz ambiental. Se pretende que esta aproximación sirva de base para el diseño de estudios relacionados con la computación afectiva<sup>2</sup>.

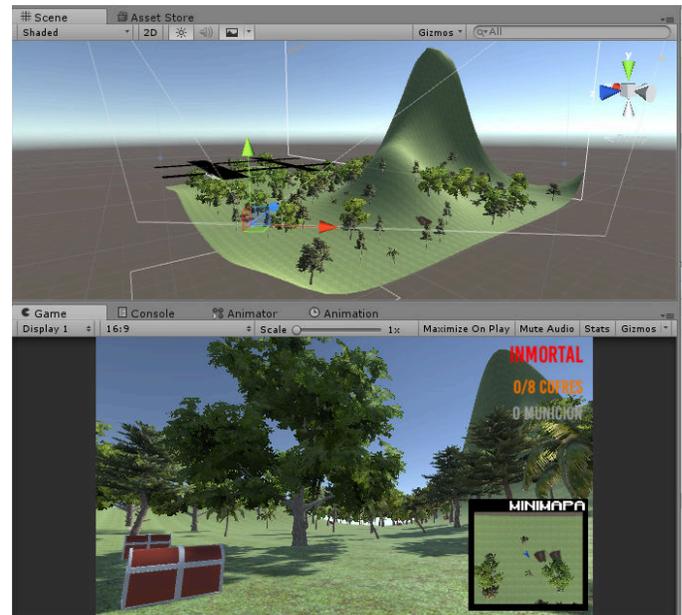
<sup>2</sup>El código fuente de este software puede descargarse bajo licencia libre en el siguiente enlace: <https://github.com/JoseManuelMartinez/GameGenerator>

En cuanto al sistema propuesto, algunas decisiones de diseño merecen ser puntualizadas. En primer lugar y dado que el objetivo era presentar un generador estocástico de partidas adaptable a la aficción emocional esperada, los criterios por los que se ha asociado cada dimensión a sus respectivas características del universo del juego no están suficientemente sustentadas. De esta forma, por ejemplo, en cierta medida es discutible la consideración de que una mayor intensidad emocional se obtiene cuando el personaje tiene más recursos, o en qué grado el tamaño del enemigo, asociado a la valencia, se solapa con otras dimensiones. No obstante, estas dependencias no son obligatorias, sino escogidas por el diseñador del juego que implemente el generador estocástico.

Por otro lado, aunque la elección de un terreno boscoso parecería limitar el alcance de la propuesta, el sistema no determina éste como el único escenario posible. Al contrario, el proceso de generación estocástica no depende de la elección del entorno ni de la mecánica, sino de las dimensiones emocionales y la formulación en cuanto a la interacción de éstas. Sin embargo, sí puede ser necesario especializar los componentes constructores debido las características del nuevo



(a) Ejemplo de juego generado 1



(b) Ejemplo de juego generado 2

Figura 7: Ejemplos de juegos generados 1 y 2

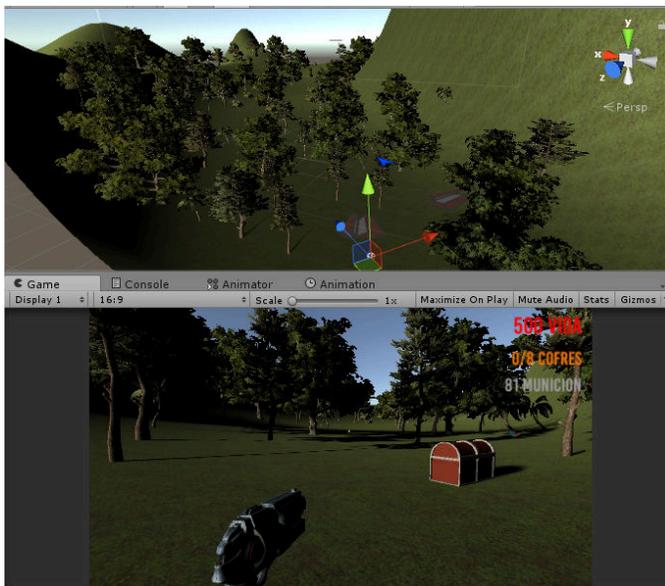


Figura 8: Ejemplo de juego generado 3

universo, lo cual queda a criterio del diseñador.

Asimismo, el entorno inmersivo-afectivo propuesto sugiere la experimentación con periféricos como gafas de realidad virtual o dispositivos de control gestuales<sup>3</sup>. Igualmente, la obtención de las respuestas fisiológicas de los jugadores mediante medidores biométricos o sensores de ondas permitiría evaluar el efecto ponderado de cada una de las dimensiones y, en su

<sup>3</sup>La versión facilitada ya incluye un módulo para la manipulación de los cofres mediante la tecnología *Leap Motion*.

caso, la detección de efectos colaterales derivados de la propia tipología del juego. Además, la posibilidad de identificación de las variaciones anímicas del jugador habilitaría nuevas estrategias en la transformación de las partidas durante su ejecución.

Se estima también que un avance sustancial en materia de inclusión dinámica de elementos efectivos vendría de la mano de la combinación del generador propuesto con un sistema de generación automática de historias [19] [20], construyendo la partida mediante la implementación de los NPC como agentes múltiples y teniendo en cuenta la decisión del jugador en momentos críticos de la trama. Esto puede ampliarse a la extensión del mapa conforme el personaje principal avanza, lo cual es aplicable tanto a su tamaño como a su tipología de acuerdo con las dimensiones afectivas y las propias interacciones con el entorno.

No obstante a ello y debido a que el objetivo del proyecto es la evocación de respuestas emocionales específicas, la validez del sistema debe ser probada mediante un estudio con usuarios finales que permita ratificar los resultados obtenidos. Un experimento para la evaluación del videojuego por parte de sujetos humanos se encuentra en fase de diseño y será incluido en posteriores contribuciones.

## REFERENCIAS

- [1] J. Takatalo, J. Häkkinen, J. Kaistinen, and G. Nyman, "Presence, involvement, and flow in digital games," in *Evaluating user experience in games*. Springer, 2010, pp. 23–46.
- [2] J. Togelius and G. N. Yannakakis, "Emotion-driven level generation," in *Emotion in Games*. Cham, Switzerland: Springer, 2016, pp. 155–166.
- [3] E. Hudlicka, "Affective computing for game design," J. Kienzle, H. Vangheluwe, and C. Verbrugge, Eds.

- [4] K. M. Gilleade, A. Dix, and J. Allanson, "Affective videogames and modes of affective gaming: Assist me, challenge me, emote me," in *Conference Proceedings of DiGRA'05, Changing Views: Worlds in Play*, Digital Games Research Association, Vancouver, Canada, 2005.
- [5] J. Komulainen, J. Takatalo, M. Lehtonen, and G. Nyman, "Psychologically structured approach to user experience in games," in *Proceedings of the 5th Nordic conference on Human-computer interaction: building bridges*. ACM, 2008, pp. 487–490.
- [6] B. Perron, "A cognitive psychological approach to gameplay emotions," in *Conference Proceedings of DiGRA'05, Changing Views: Worlds in Play*, Digital Games Research Association, vol. 3, Vancouver, Canada, 2005, pp. 1–10.
- [7] H. Wang, M. Gotsis, M. Jordan-Marsh, D. Spruijt-Metz, and T. Valiente, "Leveling up: Game enjoyment threshold model and player feedback on the design of a serious game," Buffalo, NY, pp. 1–9, 2010.
- [8] P. Toprac and A. Abdel-Meguid, "Causing fear, suspense, and anxiety using sound design in computer games," in *Game Sound Technology and Player Interaction: Concepts and Developments*, M. Grimshaw, Ed. IGI Global, 2010, ch. 9, pp. 176–191. [Online]. Available: <https://www.igi-global.com/chapter/causing-fear-suspense-anxiety-using/46792>
- [9] C. Liu, P. Agrawal, N. Sarkar, and S. Chen, "Dynamic difficulty adjustment in computer games through real-time anxiety-based affective feedback," *International Journal of Human-Computer Interaction*, vol. 25, no. 6, pp. 506–529, 2009.
- [10] J. Frome and A. Smuts, "Helpless spectators: Generating suspense in videogames and film," *TEXT technology*, vol. 13, pp. 13–34, 2004.
- [11] M. M. Bradley and P. J. Lang, "Affective norms for english words (ANEW): Instruction manual and affective ratings," Technical Report C-1, The Center for Research in Psychophysiology, University of Florida, Tech. Rep., 1999.
- [12] F. M. Citron, M. A. Gray, H. D. Critchley, B. S. Weekes, and E. C. Ferstl, "Emotional valence and arousal affect reading in an interactive way: neuroimaging evidence for an approach-withdrawal framework," *Neuropsychologia*, vol. 56, pp. 79–89, 2014.
- [13] D. E. Berlyne, "Conflict, arousal, and curiosity," *McGraw-Hill Series in Psychology*, vol. XII, 1960.
- [14] M. Montefinese, E. Ambrosini, B. Fairfield, and N. Mammarella, "The adaptation of the Affective Norms for English Words (ANEW) for Italian," *Behavior research methods*, vol. 46, no. 3, pp. 887–903, 2014.
- [15] P. Delatorre, M. Palomo-Duarte, and P. Gervás, "Formalising suspense from immersive environments," in *Proceedings of 3rd Congreso de la Sociedad Española para las Ciencias del Videjuego (CoSECiVi 2016)*, ser. CEUR Workshop Proceedings, D. Camacho, M. A. Gómez-Martín, and P. A. González-Calero, Eds., vol. 1682, Barcelona, Spain, 2016, pp. 25–36. [Online]. Available: <http://ceur-ws.org/Vol-1682/>
- [16] A. G. Hernández, "Generación aleatoria de terrenos 3d con unity," 2015.
- [17] F. K. Musgrave, C. E. Kolb, and R. S. Mace, "The synthesis and rendering of eroded fractal terrains," in *ACM Siggraph Computer Graphics*, vol. 23, no. 3. ACM, 1989, pp. 41–50.
- [18] M. Olano, "Modified noise for evaluation on graphics hardware," in *Proceedings of the ACM SIGGRAPH/EUROGRAPHICS conference on Graphics hardware*. ACM, 2005, pp. 105–110.
- [19] C. León and P. Gervás, "A top-down design methodology based on causality and chronology for developing assisted story generation systems," in *Proceedings of the 8th ACM conference on Creativity and cognition*. ACM, 2011, pp. 363–364.
- [20] R. H. García-Ortega, P. García-Sánchez, J. J. Merelo, A. San Ginés, and Á. Fernández Cabezas, "The story of their lives: Massive procedural generation of heroes' journeys using evolved agent-based models and logical reasoning," in *Applications of Evolutionary Computation - 19th European Conference, EvoApplications 2016, Porto, Portugal, March 30 - April 1, 2016, Proceedings, Part I*, ser. Lecture Notes in Computer Science, G. Squillero and P. Burelli, Eds., vol. 9597. Springer, 2016, pp. 604–619.



# How a mobile platform for emotion identification supports designing affective games

Grzegorz J. Nalepa

AGH University of Science and Technology  
al. Mickiewicza 30, 30-059 Krakow, Poland  
Email: gjn@agh.edu.pl

Barbara Gizycka

AGH University of Science and Technology  
al. Mickiewicza 30, 30-059 Krakow, Poland  
Email: bgizycka@agh.edu.pl

**Abstract**—Affective computing is a multidisciplinary area of research regarding modeling, identification, and synthesis of emotions using computer-based methods. Affective gaming is dedicated specifically to developing games that use the information regarding player’s emotional condition. Such games focus on the emotional dimension of gaming experience, to provide greater player engagement. In this short paper we give an overview of our recent works aimed at developing a mobile software platform for emotion identification using wearable devices. Furthermore, we have been working on the integration of this approach with the design and development of affective games.

## I. INTRODUCTION

In this paper we report on recent results presented in the *Future Generation Computing Systems* [1], and relate it to our most recent follow up work on applications to computer games presented at the *IEEE GEM* conference in August 2018 [2].

We believe that information regarding the affective condition of a user can lead to a better understanding of interactions of users with machines. This is one of the applications of Affective Computing (AfC), that was originally introduced in [3]. AfC builds on the assumption that emotions are both physical and cognitive, and can be modeled using low-level physiological data, such as heart rate (HR) or galvanic skin response (GSR). Numerous problems that arise regard specific measurement hardware for these signals, which should be both accessible and unobtrusive, as well as appropriate software – to handle the collected data. Wearable devices, such as wristbands, seem like a promising solution for this matter. In our research we have been working towards developing computational models of emotions, that could be used based on the measurement data from wearable devices. We envisage several uses of such models, including affective gaming.

Emotional layer of gaming experience has brought attention of many research fields [4]–[6]. Data of player’s emotional state (derived from her behavior on one or more levels, from physiological to some general behavior metrics) can be used to develop systems comprising of affect models. Affective gaming, stemming directly from a more global account – affective computing (AfC), applies precisely this approach.

In the next two sections we describe our recent works in these two areas, focusing on these two keyword papers.

## II. RESEARCH ON THE AFCAI PLATFORM

Our preliminary proposal for combining affective computing with context-aware systems for ambient intelligence applications (so-called *AfCAI* proposal) was presented in the first *AfCAI* workshop (see <https://www.affcai.eu>). It was based on the use of wearable devices as sources of affective physiological data. This data could be used to extend the notion of context in context-based reasoning [7]. We also developed new software called *Bandreader* for supporting our experimental procedures using a range of wearables [8].

The synthesis of this stage of work can be found in our recent paper [1] in *FGCS*, where we elaborate on detection of affective states, their proper identification and interpretation with use of wearable and mobile devices. We propose a data acquisition layer based on wearables to gather physiological data, and we integrate it with mobile context-aware framework.

Our solution extends the platform we developed for building mobile context-aware systems [7]. The architecture of this extended platform is presented in Fig. 1. It is an extension of standard Model-View-Controller software architectural pattern that includes context and adaptability as a part of the model. The *adaptable model* layer of the architecture is responsible for discovery and adaptation to user long-term preferences and habits (profiles), but also should provide mechanisms allowing to react on dynamically changing environmental conditions. The *context-based controller* provides mechanisms for context-based mediation between the user and the system that allows the system to resolve vagueness and incompleteness of background data. We extended this basic architecture with two components marked red in Fig. 1: 1) Physiological context provider plugin, responsible for obtaining heart rate, GSR and possibly other data from wearable sensors, and 2) Emotion detection and recognition module, which objective is the discovery of correlations between context and user emotional state. Our solution offers a non-intrusive measurement of affective thanks to the use of wearable devices, such as wristbands. As such, it is suitable for gaming environments.

## III. TOWARDS THE DESIGN OF AFFECTIVE GAMES

Our first works in the area of applications of AfC to gaming were described in [9]. We assumed that a change in the affective condition of a player can be detected based of the monitoring of physiological signals following the James-Lange

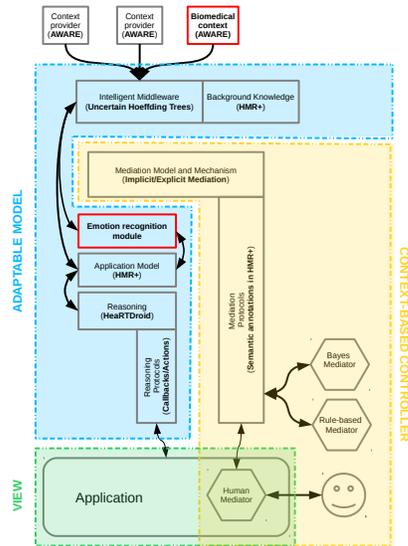


Fig. 1. Our architecture extended with emotion recognition and processing [1]

theory of emotions [10]. We build on the idea of game design patterns [11], which originate in the repetitive nature of game mechanics. We identified a preliminary set of patterns that can be considered affective. Then we demonstrated how these patterns can be used in a design of a scroll-runner game.

Affective games comprise various techniques and tools, which highlight their distinction from the regular kinds of games. We observed that they also require a thoroughly different design approach. To address this challenge, in our most recent work at *IEEE GEM* [2] we formulated a framework based on game design patterns, more specifically – affective ones. The considered patterns integrate design strategies with measuring player’s emotional reactions.

The main contribution is the proposal of the *Affective Game Design Patterns Framework*. We build on the above mentioned concept of game design patterns introduced by Björk and Holopainen [11]. Patterns form an intricate web of interrelations, and can be abstracted from different levels of interaction with the game. Furthermore, in [12] we built on this idea and discussed the application of our approach to build games with the so-called affective loop.

Our account (Fig. 2) is built on premises: 1) One can infer about their affective state based on physiological data on e.g. HR and GSR. 2) This data may be used to develop both models of affect for in-game agents and player affect, 3) By applying affective game design patterns game developers can use knowledge on the described gaming situation early in the design phase to provide affectively adaptive game world.

To evaluate our approach, four series of experiments have taken place. In [9], where we present our approach and explain our first experimental game designed with affective patterns in mind. The findings and observations from all of conducted studies allowed us to critically evaluate several measurement devices in the light of affective computing purposes. We also confirmed reliability of our custom mobile application for data acquisition from wearable devices [8].

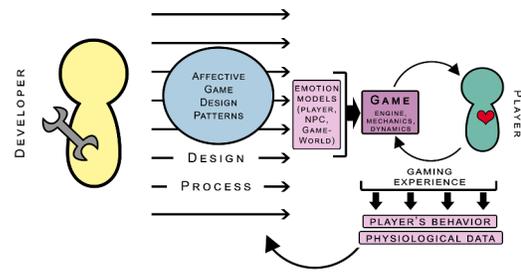


Fig. 2. Affective Game Design Patterns Framework [2]

#### IV. CONCLUSION AND FUTURE WORKS

We provided a general overview of our recent works on the intersection of affective computing and video games. Our ultimate goal is to provide a unified affective game design framework. As a foundation, we suggest the use of affective game design patterns, which are a convenient design tool that realizes the affective loop. Currently, we examine the possibilities brought by Unity API delivered for BITalino (<http://bitalino.com>) we use and experiment with our first affectively adaptive game prototypes. As for our future plans, we will aim at identifying correlations between affective game events, evoked by affective design patterns, and physiological reactions of the player.

#### REFERENCES

- [1] G. J. Nalepa, K. Kutt, and S. Bobek, “Mobile platform for affective context-aware systems,” *Future Generation Computer Systems*, 2018. [Online]. Available: <https://doi.org/10.1016/j.future.2018.02.033>
- [2] B. Giżycka and G. J. Nalepa, “Emotion in models meets emotion in design: building true affective games,” 2018, accepted to *IEEE GEM* 2018.
- [3] R. W. Picard, *Affective Computing*. MIT Press, 1997.
- [4] K. M. Gilleade and A. Dix, “Using frustration in the design of adaptive videogames,” in *Proceedings of the 2004 ACM SIGCHI International Conference on Advances in Computer Entertainment Technology*, ser. ACE ’04. New York, NY, USA: ACM, 2004, pp. 228–232. [Online]. Available: <http://doi.acm.org/10.1145/1067343.1067372>
- [5] R. El Kaliouby, R. Picard, and S. Baron-Cohen, “Affective computing and autism,” *Annals of the New York Academy of Sciences*, vol. 1093, no. 1, pp. 228–248, 2006.
- [6] K. Gilleade, A. Dix, and J. Allanson, “Affective videogames and modes of affective gaming: assist me, challenge me, emote me,” *DiGRA 2005: Changing Views—Worlds in Play*, 2005.
- [7] S. Bobek and G. J. Nalepa, “Uncertain context data management in dynamic mobile environments,” *Future Generation Computer Systems*, vol. 66, no. January, pp. 110–124, 2017. [Online]. Available: <http://dx.doi.org/10.1016/j.future.2016.06.007>
- [8] K. Kutt, G. J. Nalepa, B. Giżycka, and P. Jemioło, “Bandreader – a mobile application for data acquisition from wearable devices in affective computing experiments,” accepted to HSI 2018.
- [9] G. J. Nalepa, B. Giżycka, K. Kutt, and J. K. Argasinski, “Affective design patterns in computer games. scrollrunner case study,” in *Communication Papers of the 2017 Federated Conference on Computer Science and Information Systems, FedCSIS 2017*, 2017, pp. 345–352. [Online]. Available: <https://doi.org/10.15439/2017F192>
- [10] W. James, “What is an emotion?” *Mind*, no. 34, pp. 188–205, 1884.
- [11] S. Björk and J. Holopainen, *Patterns in Game Design*. Charles River Media, 2005.
- [12] B. Giżycka, G. J. Nalepa, and P. Jemioło, ““Aided with emotions” – a new design approach towards affective computer systems,” *ArXiv e-prints*, Jun. 2018.



# Desarrollo de un Modelo Estándar de Interacción para Entornos Virtuales

Juan Luis Berenguel Forte\*, Francisco Luis Gutiérrez Vela†, Patricia Paderewski Rodríguez‡ y Daniel Pérez Gázquez§

Escuela Técnica Superior de Ingenierías Informática y de Telecomunicación

Universidad de Granada

Granada, España

\*Email: juanlubf@ugr.es

†Email: fgutierr@ugr.es

‡Email: patricia@ugr.es

§Email: danielpg@ugr.es

**Resumen**—Dentro del ámbito de los videojuegos de inmersión virtual existe gran variedad de modelos de interacción, ya que los desarrolladores utilizan técnicas muy específicas para sus aplicaciones. Este trabajo trata de recopilar información acerca de las distintas técnicas existentes dentro de dichos entornos virtuales, ya sea bajo el paradigma de la realidad virtual (RV) o el paradigma de la realidad aumentada (RA), para extraer un modelo estándar que satisfaga las necesidades de los desarrolladores y permita la implementación de una librería que de soporte a las interacciones descritas en dicho modelo.

## I. INTRODUCCIÓN

Las aplicaciones que se desarrollan para entornos tanto de realidad virtual como de realidad aumentada necesitan usar técnicas de interacción que se adapten a los dispositivos de entrada (mandos, *joysticks*, móviles táctiles ...) y dispositivos de salida (móviles, gafas, proyectores ...) que los sistemas de realidad virtual y aumentada proporcionan a los usuarios. Aunque estos entornos virtuales (EV) llevan varias décadas entre nosotros, la mayor parte de la investigación se ha centrado en el desarrollo de la tecnología que la sustenta [1], por lo que nos encontramos que el uso de técnicas de interacción no está generalizado y cada aplicación usa e implementa técnicas muy específicas. Una gran parte de las aplicaciones que se desarrollan para estas tecnologías son videojuegos, por lo que el uso de técnicas correctas en estos entornos pueden ser la clave para conseguir que un videojuego sea un éxito o un fracaso, ya que influyen en gran medida sobre la experiencia que va a percibir el jugador.

Teniendo en cuenta esta necesidad, en este trabajo proponemos un modelo de abstracción de las técnicas de interacción para ambos paradigmas que permita generalizar las técnicas existentes e implementar un proyecto de prueba de distintas técnicas que de soporte a los desarrolladores a la hora de determinar qué técnicas utilizar.

## II. MOTIVACIÓN

Dado que en la actualidad no existe un modelo estándar de interacción para entornos virtuales, se produce una discordancia entre las necesidades de los usuarios de este tipo de software y las implementaciones que se realizan. En ocasiones,

este problema puede desembocar en el aumento de la dificultad para el desarrollo de una aplicación efectiva por parte de los desarrolladores, o en la implementación de una técnica no adecuada para el contexto de uso de la aplicación.

En el caso de las aplicaciones de realidad virtual el problema se incrementa, pues implementar un sistema de navegación dentro de este entorno suele resultar dificultoso debido a los problemas relacionados con la sensación de mareo, la pérdida de inmersión y la desorientación, producto de sentir que se está realizando un desplazamiento, pero el cuerpo no se está moviendo físicamente.

### II-A. Objetivos propuestos

El propósito de este trabajo consiste en realizar una revisión de las principales técnicas de interacción existentes, atendiendo a su facilidad de uso y a su extensión dentro de los entornos virtuales, así como de otras propuestas anteriores de clasificación de dichas técnicas de interacción, para proponer un modelo abstracto que permita a los desarrolladores tener una guía de implementación para saber cuáles son las mejores técnicas y por qué para las necesidades específicas de su proyecto sin que tengan que recurrir a implementar las suyas propias.

Como trabajo paralelo a este análisis de las técnicas de interacción se implementará un proyecto de ejemplo que permita utilizar las técnicas de mayor relevancia (tanto para realidad virtual como para realidad aumentada) para poner a prueba el modelo y poder evaluar la experiencia de los usuarios. Esto nos permitirá poder evaluar tanto el modelo de interacción propuesto, como las propias técnicas que sean implementadas.

## III. ESTADO DEL ARTE

En la literatura científica existen muchos trabajos donde sus autores proponen distintos modelos de clasificación de las interacciones que se dan lugar entre los usuarios y el entorno virtual. En esta sección se citarán algunos de los trabajos que se han encontrado más relevantes para nuestro objetivo.

En [2] se propone una clasificación en 2 grandes categorías principales, que luego se subdividen en varias subcategorías:

- Técnicas egocéntricas: engloba las técnicas que permiten al usuario fundirse con el entorno virtual. Se subdivide en manipulación directa, control físico y control virtual.
- Técnicas exocéntricas: engloba las técnicas que hacen que el usuario no se sumerja en el entorno virtual, sino que se siente un elemento ajeno a este. Se subdividen en manipulación directa, control físico y control virtual.

En [3] se propone una división de las técnicas de interacción en RA en tangibles (se basan en interactuar con un dispositivo físico) e intangibles (se basan en interactuar sin el dispositivo físico). Esta categorización de las técnicas se verá con más detalle en la sección V-B. Adicionalmente, en este trabajo midieron el grado de usabilidad que presentaba cada conjunto de técnicas, resultando el grupo de técnicas tangibles ser el que resultaba más fácil de usar y menos estresante para los usuarios. No obstante, las técnicas intangibles resultaron ser más atractivas y divertidas para los usuarios.

En [4] se propone una categorización de las técnicas en 3 modalidades:

- Interacción directa del usuario: engloba todas las técnicas que requiere el reconocimiento del cuerpo del usuario (seguimiento de manos, reconocimiento de gestos, etc).
- Controles físicos: engloba las técnicas que requieren la utilización de un dispositivo físico, como botones, *joysticks*, volantes, etc.
- Controles virtuales: engloba las técnicas que utilizan un elemento virtual como medio de interacción con el entorno. Dentro de este ámbito, prácticamente cualquier elemento virtual puede ser utilizado para tal propósito.

#### IV. TÉCNICAS DE INTERACCIÓN EN ENTORNOS VIRTUALES

El campo de la Interacción Persona-Ordenador (IPO) abarca los campos de estudio relativos al diseño, estudio y planificación de la interacción producida entre los humanos y las computadoras [3]. Dentro del campo de la IPO existen técnicas de interacción especialmente dirigidas a los entornos virtuales, las cuales definen el conjunto de interacciones que pueden realizar las personas para relacionarse con el entorno, ya sea mediante el uso de un dispositivo o no.

Con el aumento de la publicación de videojuegos que utilizan estos entornos virtuales como plataforma, la investigación en técnicas de interacción en entornos virtuales cobra una gran importancia, pues son la clave de una buena inmersión del jugador en dichos entornos, lo cual se traduce en mayor disfrute por parte del jugador y mayor probabilidad de éxito para el videojuego.

Podemos dividir las interacciones en dos grandes grupos: interacciones avanzadas e interacciones básicas.

Según [4], las interacciones básicas en los entornos virtuales se pueden dividir en los siguientes grupos: selección, manipulación, escalamiento, navegación e interacción con menús virtuales y *widgets*. No obstante, las interacciones se pueden

clasificar en dos paradigmas distintos, en función de si operamos en realidad virtual (local y a distancia) o en realidad aumentada (tangible e intangible), tal y como se verá en el capítulo V.

Por otro lado, las interacciones avanzadas serían aquellas que están compuestas por un conjunto de interacciones básicas. Como ejemplo, la acción de lanzar una pelota sería una interacción avanzada compuesta por una selección y serie de acciones de manipulación. Debido a esta relación de composición, sólo analizaremos en profundidad las interacciones básicas.

##### IV-A. Selección

Según [5], la selección de un objeto virtual hace referencia al acto de elegir o especificar un objeto en concreto para un propósito específico. Este acto de selección debe dividirse en dos pasos: primero se ha de identificar el objeto a seleccionar y después se procede a realizar la selección de dicho objeto identificado.

Para realizar la selección de un objeto virtual podemos usar distintas técnicas atendiendo al tipo de entorno virtual en el que estemos. En realidad virtual podemos usar técnicas locales o a distancia, y en realidad aumentada, podemos usar técnicas tangibles e intangibles.

Además, también es necesario que el usuario reciba algún tipo de *feedback* para saber que la selección se ha realizado exitosamente [4].

##### IV-B. Manipulación

La interacción de manipular un objeto en un entorno virtual hace referencia a la tarea de modificar las propiedades de la posición y la orientación de dicho objeto. Es necesario destacar que para realizar la manipulación de un objeto es necesario haber realizado una selección previa de dicho objeto, aunque para realizar la selección de un objeto no es necesaria la manipulación del mismo. Nuevamente, para realizar estas acciones disponemos de técnicas locales y a distancia (en RV), y de técnicas tangibles e intangibles (en RA).

Dentro de la manipulación hay 3 aspectos esenciales a controlar: el cambio en la posición, el cambio en la orientación y el centro de rotación [4].

El **cambio en la posición** hace referencia al número de unidades de distancia en el mundo virtual en las que dicho objeto es desplazado, además de en qué eje(s) se produce el desplazamiento. La correspondencia entre las unidades de distancia del mundo virtual y las del mundo real puede ser 1:N, es decir, el objeto no tiene por qué desplazarse en el mundo virtual de forma análoga al desplazamiento que nosotros realicemos en el mundo real.

El **cambio en la rotación** hace referencia al número de unidades de rotación en el mundo virtual en las que dicho objeto es rotado, además de en qué eje(s) se produce la rotación. Al igual que con la posición, es posible establecer una correspondencia 1:N entre el mundo virtual y el mundo real.



El **centro de rotación** es el punto en torno al cuál el objeto realizará la rotación. Dicho punto puede ser el centro del objeto virtual u otro punto establecido arbitrariamente por el usuario.

Como ejemplo de una de las técnicas de manipulación en RV más utilizadas se ha observado el uso de los mandos como manos virtuales y el botón de disparo trasero para simular el agarre de un objeto de virtual para luego moverlo y/o rotarlo.

#### IV-C. Escalamiento

El escalamiento consiste en modificar el tamaño de un objeto dentro del mundo virtual, ya sea para hacerlo más grande o para hacerlo más pequeño. Al igual que la manipulación, necesita que se haya realizado previamente la selección del objeto que se pretende escalar y se puede realizar mediante técnicas locales y a distancia (en RV) y mediante técnicas tangibles e intangibles (en RA).

Para escalar un objeto es necesario definir dos parámetros clave: el centro de escala y el factor de escala [4].

El **centro de escala** es el punto que se utilizará como referencia para realizar el escalamiento: los puntos del objeto se acercarán al centro de escala cuando se disminuya el tamaño del objeto y se alejarán de dicho centro cuando se aumente el tamaño del objeto. Al igual que pasaba con el centro de rotación, este punto puede ser el centro del objeto o cualquier otro punto arbitrario determinado por el usuario.

El **factor de escala** define el número de unidades de tamaño que aumentará o disminuirá el objeto virtual al ser escalado. Al igual que en el desplazamiento y la rotación, no tiene por qué guardar una relación 1:1 con el mundo real.

#### IV-D. Navegación

Uno de los aspectos fundamentales en el desarrollo de aplicaciones en entornos de realidad virtual es la navegación, ya que tal y como se explica en [6], el proceso de moverse por un entorno de realidad virtual puede producir mareos, e incluso vómitos, a los usuarios, aunque no siempre afecta de la misma manera a todos los usuarios, pues existen caracteres diferenciadores, tales como el género, la edad y la predisposición.

Por otra parte, en las aplicaciones de realidad aumentada generalmente la navegación no supone ningún problema, ya que para que se produzca un movimiento de la cámara, se ha de mover el dispositivo que se está utilizando para ver los objetos virtuales, lo cual implica el propio movimiento del usuario, que es consciente en todo momento de su situación en el mundo real (al contrario que sucede en la realidad virtual).

Según [7], la navegación consiste en seguir un curso mediante movimientos dirigidos. Unido a esta definición de navegación, también define el concepto de *wayfinding* (localización de camino) como la determinación de una estrategia, dirección y curso necesarios para alcanzar un destino deseado.

Para conseguir una navegación efectiva dentro de los entornos de realidad virtual es necesario tener en cuenta un serie de **factores que afectan a la navegación**, que se derivan directamente de 6 características que están relacionados entre

sí: entorno, usuario, tarea, estrategia de navegación, ayudas a la navegación y controles de movimiento [8].

**Entorno** describe atributos que están directamente relacionados con la estructura del mundo virtual como el tamaño, el grado de abstracción a representar o si se trata de un entorno multiusuario o no. Es un factor que depende en gran medida del tipo de aplicación.

**Usuario** define las características que tiene un usuario, como su edad, su género, sus habilidades y sus debilidades.

**Tarea** define el objetivo que el usuario pretende conseguir dentro de la aplicación. La navegación deberá ser acorde al tipo de aplicación y al objetivo que tenga el usuario.

**Estrategia de navegación** describe conceptos que se usan para navegar por un entorno, tales como “buscar”, “navegación vectorial” y “navegación posicional”, que a su vez se componen de acciones básicas como “alcanzar el objetivo”, “seguir el curso” o “seguir la pared” [9].

Las **ayudas a la navegación** consisten en un conjunto de ayudas (que pueden ser parte del entorno u objetos externos) que ayudan al usuario a determinar la dirección de la navegación, a determinar su posición o ambas cosas.

Los **controles de movimiento** abarcan tanto los dispositivos *hardware* como el *software* necesarios para realizar la navegación dentro del mundo virtual.

Un aspecto importante a tener en cuenta son los **tipos de navegación**, ya que la navegación en entornos de realidad virtual se puede llevar a cabo utilizando distintos paradigmas, de hecho, es normal encontrar aplicaciones de realidad virtual que implementan más de un tipo de navegación. Los paradigmas más usados son la navegación basada en vuelo, navegación de movimiento libre, navegación de movimiento vehicular, navegación basada en nodos, navegación de escalada, teletransportación basada en arco, navegación basada en un avatar fantasma, navegación usando puntos mallados, teletransporte a cámaras prefijadas y navegación basada en parpadeo (*blink*) [6]. Asimismo, también existe la navegación en raíles [10], la navegación basada en la inclinación del usuario [11], la navegación por gestos [12] e, incluso, es posible utilizar elementos *hardware* específicos que nos permiten navegar por el mundo virtual aumentando el grado de inmersión y de simulación de la realidad.

La navegación basada en arco es uno de los tipos de navegación más utilizados, la cual consiste en lanzar desde el mando un rayo virtual parabólico que nos indica en el suelo dónde vamos a ser teletransportados una vez soltemos el botón.

Por último, cabe destacar que también existen aplicaciones de realidad virtual donde el entorno se construye de forma que el usuario no tenga que desplazarse por el mundo virtual, con lo que se evita la navegación.

#### IV-E. Interacción con menús virtuales y widgets

La interacción con menús virtuales dentro de los entornos virtuales ofrece a los usuarios una nueva forma de poder interactuar con los objetos de dichos entornos, en ocasiones, facilitando tareas que serían complejas de otra manera. Según [4], los menús de interacción pueden tener una, dos o incluso

tres dimensiones, con una relación directa de aumento de posibilidades de interacción y de complejidad de manejar. No obstante, existen ciertos problemas y limitaciones que son independientes de la dimensión del menú, tales como la posición óptima para colocar el menú dentro de la interfaz del usuario o cómo acceder a él (utilizando un botón, un comando de voz, un gesto específico, etc).

Dentro de este ámbito, un ejemplo común de interacción sería la manipulación directa de objetos de interfaz virtuales, tales como pulsar un botón o desplazar una guía.

## V. MODELO DE ABSTRACCIÓN PROPUESTO

Tanto en los entornos de realidad virtual y de realidad aumentada, la gran variedad de formas de interacción entre los usuarios y las aplicaciones genera problemas a los desarrolladores, que no disponen de un modelo estándar y simplificado que les permita decidir qué tipo de interacción es la más adecuada para las necesidades de su aplicación. No obstante, ambos entornos comparten ciertas similitudes que permiten proponer un modelo que pueda aportar una solución genérica para ciertas interacciones comunes.

Para poder establecer un modelo abstracto de las interacciones es necesario establecer una correspondencia entre una necesidad real de interacción en un entorno específico y una o varias técnicas que la satisfagan. Por lo tanto, es imperante conocer las necesidades del desarrollador, que para poder definir las se pueden dividir en tres pasos: qué se quiere hacer, cómo se quiere hacer y las necesidades específicas (si las hubiere) relacionadas con el contexto específico de uso de la aplicación. Esta división se verá con detalle en la sección V-D.

Asimismo, para realizar el proceso de abstracción que englobe ambos entornos virtuales, es necesario entender en qué tipos de paradigmas se clasifican las interacciones en entornos de realidad virtual y de realidad aumentada para poder abstraerse aún más y proponer un modelo más abstracto que nos permita definir una categorización que abarque tanto las técnicas de realidad virtual como las de realidad aumentada pero manteniendo la posibilidad de profundizar y realizar una clasificación más concreta hasta llegar al nivel de implementación.

Según [4], en un entorno de realidad virtual se pueden diferenciar técnicas según si la interacción entre el usuario y el entorno virtual se hace a nivel local o a distancia.

Por otra parte, según [3], dentro del ámbito de la realidad aumentada, podemos clasificar principalmente las interacciones en dos grandes categorías: técnicas tangibles y técnicas intangibles.

### V-A. Interacción en realidad virtual

Cuando utilizamos aplicaciones de realidad virtual contamos con un dispositivo visualizador (*Head Mounted Display*, HMD), uno o más controles físicos (mandos) y, en ocasiones, otros dispositivos auxiliares, como sensores, que nos ayudan a posicionar a los usuarios, u otros objetos, en el espacio virtual. El uso de estos dispositivos permite que podamos

tener una representación virtual de un elemento del mundo real. Por ejemplo, el mando que usamos en el mundo real, se transforma en una mano dentro del mundo virtual que podemos controlar mediante los botones y el movimiento de dicho mando. No obstante, estos dispositivos también pueden ayudarnos a interacciones con elementos que no estén a nuestro alcance.

Por lo tanto, en el ámbito de la realidad virtual las interacciones se pueden realizar de dos formas principalmente: de forma local y a distancia [4].

En la **interacción local** el usuario, que es posicionado en el mundo virtual mediante el HMD, ha de estar en una posición cercana al objeto virtual y, utilizando uno de los mandos, que es visualizado dentro del entorno virtual (generalmente como una mano virtual) puede interactuar con el objeto deseado. Es decir, en este paradigma de interacción es necesario que el objeto virtual esté al alcance de la mano del usuario dentro del entorno virtual.

En la **interacción a distancia** existe mayor libertad de acción, pues el usuario puede utilizar, nuevamente, un mando para apuntar a distancia a un objeto y seleccionarlo (*raycasting*), seleccionar el objeto que esté mirando, seleccionar un objeto mediante gestos o, incluso, mediante comandos de voz.

### V-B. Interacción en realidad aumentada

En la realidad aumentada se utiliza un dispositivo con una cámara que nos permite ver objetos virtuales superpuestos en nuestro entorno físico. Por ello, en el ámbito de la realidad aumentada podemos interactuar de manera tangible y de manera intangible.

La **interacción tangible** es cualquier interacción en la que el usuario utiliza un dispositivo físico para llevarla a cabo [3]. Esta puede ser de dos tipos: basada en toque, donde el usuario selecciona un objeto tocando la pantalla de un dispositivo, o basada en dispositivo, donde la interacción se realiza por medio de los datos recopilados de los sensores del dispositivo, como el acelerómetro.

La **interacción intangible** hace referencia al tipo de interacción que se realiza sin una interacción física del usuario con la máquina (gestos en el aire, interacción por voz, etc) [3]. Las interacciones intangibles se pueden dividir en dos grupos: basadas en marcadores y no basadas en marcadores.

### V-C. Abstracción de las técnicas de interacción

Tal y como se vio en la sección V-B y según el criterio de clasificación de [3], dentro del ámbito de la realidad aumentada, las interacciones implementadas se pueden clasificar en: tangibles e intangibles.

Adicionalmente, tal y como se vio en la sección V-A, en [4] se clasifican las técnicas de interacción dentro de los entornos de realidad virtual en técnicas locales y a distancia.

Utilizando como fuente estas dos nomenclaturas, se propone una clasificación más abstracta, que divide las interacciones en directas e indirectas, y permita generalizar la clasificación de las técnicas de interacción tanto de realidad virtual como de realidad aumentada, con el fin de exponer las características



comunes a ambos entornos. Utilizando esta clasificación, se puede realizar una correspondencia entre las acciones que podemos realizar en ambos entornos virtuales, a qué necesidad real corresponden y qué posibles implementaciones podemos utilizar para satisfacer dichas necesidades, según el tipo de técnica que queramos usar.

**Interacción directa.** Este grupo de interacciones engloban todas aquellas interacciones en las que el usuario se relaciona de una forma directa, es decir, sin ningún tipo de intermediario con un objeto virtual. Para ello, puede utilizar tanto interacciones con su propio cuerpo (tales como gestos o comandos de voz), como interacciones que utilicen un dispositivo físico (por ejemplo, coger un objeto virtual con un mando). Los dispositivos físicos no se consideran como intermediarios porque en el entorno virtual actúan como un elemento que es capaz de virtualizar una parte del cuerpo del usuario o una interacción suya. En el apartado de interacción indirecta se explican con más detalle los elementos considerados como intermediarios.

Tal y como se explicó anteriormente, esta categoría estaría a un nivel más alto de abstracción que las interacciones mostradas en la sección, por lo que dentro de ésta podrían incluirse tanto técnicas de interacción local y a distancia, para realidad virtual, y técnicas de interacción tangible e intangible para realidad aumentada.

**Interacción indirecta.** Este tipo de interacciones están basadas en la utilización de un elemento virtual intermediario que sirve para interactuar con otro objeto virtual. Tal y como se comentó en el apartado de interacción directa, los mandos utilizados en realidad virtual no se consideran elementos intermediarios debido a que en realidad son dispositivos físicos del mundo real que simplemente permiten tener una representación virtual de ellos mismos.

Por lo tanto, un elemento intermediario será todo aquel que existe únicamente dentro del entorno virtual. Esto también es aplicable a la realidad aumentada, donde el dispositivo utilizado para visualizar los elementos virtuales tampoco es considerado un intermediario. Un ejemplo de este tipo de interacción podría ser utilizar un bate de béisbol virtual para golpear una pelota, también virtual.

Al igual que en las interacciones directas, en esta clasificación estarían incluidas tanto técnicas locales, técnicas a distancia, técnicas tangibles y técnicas intangibles.

#### V-D. Guía de diseño

Una vez conocido cómo se agrupan las técnicas de interacción, podemos empezar a establecer de qué manera se han de guiar las necesidades de los desarrolladores para que sepan de qué técnicas disponen para sus aplicaciones y qué características tienen, ya que esto será un aspecto fundamental para el contexto de uso de la aplicación. Ya que la categorización de las técnicas realizada en la sección anterior corresponde a un planteamiento a nivel de diseño, las necesidades básicas del desarrollador (qué quiere hacer y cómo quiere hacerlo) se mapearán también a este nivel de abstracción. En último lugar, las necesidades específicas de la aplicación marcarán qué tipo

de implementación se usará, una vez establecido el criterio de filtro a nivel de diseño. Para establecer estos criterios de selección se puede hacer con una estructura de pregunta - respuesta.

**Qué hacer** define la acción que se desea realizar. Puede tratarse tanto a nivel de interacciones básicas como a nivel de interacciones avanzadas (ver sección IV). Esta decisión se encuentra en la capa de diseño.

Ejemplo: “Quiero lanzar una pelota en RV” - “Debes implementar técnicas de selección y manipulación”.

**Cómo hacerlo** define cómo se quiere llevar a cabo la acción. Es decir, define si se quiere interactuar a distancia, de forma tangible, por voz, por gestos, etc. Esta decisión se encuentra también en la capa de diseño, pero condiciona la implementación, pues si se quiere, por ejemplo, realizar la interacción a distancia, ya no se pueden usar técnicas locales.

Ejemplo: “Quiero realizar el lanzamiento sin desplazarme físicamente ni virtualmente” - “Debes implementar técnicas de selección a distancia (por ejemplo, *raycasting* para interacción directa o menú virtual para interacción indirecta)”.

**Preferencias** define las necesidades concretas que los desarrolladores pueden tener en el contexto de uso de la aplicación. Por ejemplo, a la hora de implementar un sistema de navegación se puede querer usar el que produzca mayor sensación de inmersión, el que produzca menor sensación de mareo, etc. Esta decisión se encuentra en la capa de implementación, pues estas necesidades se cubrirán dependiendo de la implementación concreta utilizada para un tipo de interacción.

Ejemplo: “Quiero que el lanzamiento sea realista” - “Debes realizar las acciones de manipulación (desplazamiento y rotación de la pelota) de forma local y directa para emular el lanzamiento de la pelota con el mando”.

#### VI. VALIDACIÓN DEL MODELO PROPUESTO

Con el fin de poner a prueba el uso del modelo propuesto, se ha implementado una aplicación, tanto en realidad virtual como en realidad aumentada, que permite al usuario elegir qué tipo de interacción desea realizar para una acción simple (por ejemplo, seleccionar y rotar un objeto virtual). De esta manera, se pueden obtener dos corrientes de *feedback*:

1. Validar el modelo propuesto. Al poner a prueba el modelo propuesto con usuarios reales (desarrolladores) se puede corroborar la correctitud y la facilidad de uso del modelo propuesto, pues es imperante que los desarrolladores encuentren la clasificación de las técnicas intuitiva y fácil de comprender.
2. La usabilidad de las técnicas. Como resultado paralelo, se puede estudiar la usabilidad de cada tipo de técnica para conocer más detalles y poder ofrecer más información a los desarrolladores acerca de los puntos fuertes y débiles de las mismas. Estos datos se podrán contrastar y complementar con los de otros estudios, como los realizados en [3], tal y como se mencionó en la sección III.

La implementación de ambas aplicaciones se ha hecho utilizando el motor de videojuegos Unity [13]. La elección

de este motor de videojuegos es debido a su facilidad de uso (tanto en curva de aprendizaje como por su licencia gratuita) y su compatibilidad con otros *frameworks* necesarios para el desarrollo de este proyecto.

Para la aplicación de realidad virtual se utiliza el *framework* SteamVR [14], ya que permite compatibilidad con distintos dispositivos *hardware*, es gratuito y, además, ofrece multitud de proyectos y herramientas de ejemplo para ayudar a los desarrolladores a empezar a implementar aplicaciones de realidad virtual con Unity. Se han implementado un total de 7 tipos de navegación (movimiento libre normal y alternativo, teletransporte libre y de nodos, dash, movimiento de brazos y escalada), ya que la navegación en entornos de realidad virtual suele dar más problemas, por lo que resulta de mayor importancia en el estudio.

Para la aplicación de realidad aumentada se ha utilizado el *framework* de Vuforia [15], ya que viene integrado de forma nativa en las últimas versiones de Unity, es compatible con dispositivos móviles Android e iOS, es gratuito y cuenta con tutoriales que permiten a cualquier usuario comenzar a desarrollar sus aplicaciones de forma rápida y sencilla. Se implementaron técnicas de interacción tangibles, directas e indirectas, e intangibles, directas e indirectas.

## VII. CONCLUSIONES Y TRABAJO FUTURO

Tal y como se ha expuesto en la sección II, ha quedado patente el problema existente para los desarrolladores de aplicaciones de realidad virtual y realidad aumentada para implementar correctamente técnicas de interacción que resulten agradables a los usuarios.

Con el objetivo de dar una solución a este problema, se ha propuesto un modelo de interacción más abstracto, que sirve tanto para las interacciones en entornos de realidad virtual como realidad aumentada. Dicho modelo va acompañado de la implementación en ambos entornos de distintas técnicas de interacción para poder evaluar y corroborar la usabilidad del mismo, así como la usabilidad de las distintas técnicas, con el fin de poder brindar a los desarrolladores una guía de qué tipo de interacción deben usar en sus aplicaciones, atendiendo a diferentes criterios.

Las aplicaciones se pusieron a prueba con usuarios reales, donde éstos valoraron que la mejor técnica de navegación en realidad virtual era la escalada, en gran parte debido a su similitud por el movimiento real de los brazos al escalar. Por otra parte, en la aplicación de realidad aumentada, la técnica mejor valorada fue la tangible directa, debido a que es una forma de interacción que está ampliamente normalizada en nuestra sociedad.

Como trabajo futuro, se plantea el proceso de puesta a prueba del modelo con desarrolladores reales para comprobar la facilidad de uso del modelo. Asimismo, se plantea el proceso de ampliar las aplicaciones de prueba para testear más técnicas de interacción con usuarios y poder completar la guía de diseño para desarrolladores.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía y Competitividad de España dentro del proyecto DISPERSA (TIN2015-67149-C3-3-R).

## REFERENCIAS

- [1] M. Billinghurst, H. Kato, and S. Myojin, "Advanced Interaction Techniques for Augmented Reality Applications," *LNCS*, vol. 5622, pp. 13–22, 2009.
- [2] J. Jung, H. Park, D. Hwang, M. Son, D. Beck, J. Park, and W. Park, "A Review on Interaction Techniques in Virtual Environments," in *2014 International Conference on Industrial Engineering and Operations Management*, 2014, pp. 1582–1590.
- [3] L. Ahmed, S. Hamdy, D. Hegazy, and T. El-Arif, "Interaction techniques in mobile augmented reality: State-of-the-art," in *2015 IEEE Seventh International Conference on Intelligent Computing and Information Systems (ICICIS)*, Dec 2015, pp. 424–433.
- [4] M. R. Mine, "Virtual environment interaction techniques," Chapel Hill, NC, USA, Tech. Rep., 1995.
- [5] D. A. Bowman, "Interaction techniques for immersive virtual environments: Design, evaluation, and application," *Journal of Visual Languages and Computing*, vol. 10, pp. 37–53, 1998.
- [6] M. J. Habgood, D. Wilson, D. Moore, and S. Alapont, "Hci lessons from playstation vr," in *Extended Abstracts Publication of the Annual Symposium on Computer-Human Interaction in Play*, ser. CHI PLAY '17 Extended Abstracts. New York, NY, USA: ACM, 2017, pp. 125–135.
- [7] T. T. Elvins, "Wayfinding 2: The lost world," *SIGGRAPH Comput. Graph.*, vol. 31, no. 4, pp. 9–12, Nov. 1997.
- [8] S. Volbracht and G. Domik, "Developing Effective Navigation Techniques in Virtual 3D-Environments," *Proceedings of the Eurographics Workshop*, pp. 55–64, 2000.
- [9] B. Krieg-Brückner, T. Röfer, H. Carmesin, and R. Müller, "A taxonomy of spatial knowledge for navigation and its application to the bremen autonomous wheelchair," in *Spatial Cognition, An Interdisciplinary Approach to Representing and Processing Spatial Knowledge*, 1998, pp. 373–398.
- [10] E. Nevala, "Design guide for room scale vr," <https://www.gamedev.net/articles/game-design/game-design-and-theory/design-guide-for-room-scale-vr-r4355/>, accedido: junio de 2018.
- [11] P. Locomoto, "Lean walk," <https://www.realovirtual.com/noticias/5326/project-locomoto-presenta-su-sistema-movimiento-inclinacion>, accedido: junio de 2018.
- [12] J. C. S. Cardoso, "Comparison of gesture, gamepad, and gaze-based locomotion for vr worlds," in *Proceedings of the 22Nd ACM Conference on Virtual Reality Software and Technology*, ser. VRST '16. New York, NY, USA: ACM, 2016, pp. 319–320.
- [13] Unity, <https://unity3d.com>, accedido: junio de 2018.
- [14] Steam, <https://steamcommunity.com/steamvr>, accedido: junio de 2018.
- [15] Vuforia, <https://www.vuforia.com/>, accedido: junio de 2018.

# **II Workshop en Big Data y Análisis de Datos Escalable (II BigDADE)**

AMPARO ALONSO BETANZOS

MARÍA JOSÉ DEL JESUS

FRANCISCO HERRERA





**II Workshop en  
Big Data y Análisis  
de Datos Escalable  
(II BigDADE)**

SESIÓN 1







# Una primera aproximación para la extracción de patrones emergentes en flujos continuos de datos

A.M. Garcia-Vico, C.J. Carmona, P. González, M.J. del Jesus  
 Departamento de Informática, Data Science and Computational Intelligence  
 Universidad de Jaén, Jaén, España  
 {agvico|ccarmona|pglez|mjjesus}@ujaen.es

**Resumen**—A día de hoy, la cantidad de información proveniente de fuentes que emiten constantemente datos es inmensa, por lo que se hace necesario la extracción automática de conocimiento para la mejora de servicios en la vida cotidiana de las personas. La búsqueda de patrones emergentes permite la descripción de las características discriminativas entre clases o la descripción de tendencias emergentes en los datos. En este trabajo se presenta un nuevo enfoque basado en un sistema evolutivo difuso para la extracción de patrones emergentes en flujos continuos de datos. Los resultados del estudio experimental muestran unos resultados prometedores para la extracción de este tipo de conocimiento en el ámbito de la minería de flujo de datos.

**Index Terms**—Descubrimiento de reglas descriptivas supervisadas, minería de patrones emergentes, algoritmos evolutivos multi-objetivo, minería de flujo de datos.

## I. INTRODUCCIÓN

Vivimos en la era de la información. A día de hoy, el desarrollo en las tecnologías de la información y la comunicación ha permitido un aumento exponencial en la cantidad de datos generados. Esto se debe principalmente al abaratamiento de los sistemas de almacenamiento y sensores generadores de datos [1]. Toda esta cantidad de datos contiene conocimiento muy relevante para las empresas para poder mejorar sus servicios [3] lo que ha propiciado el desarrollo en los últimos años de técnicas de extracción de conocimiento en estos enormes volúmenes de información heterogénea en lo que se conoce como *Big Data* [2]. Sin embargo, existen ámbitos de trabajo, como por ejemplo en gestión de energía [4], donde los datos muy antiguos son completamente irrelevantes. En este caso, un análisis continuo de la información conforme los datos van llegando es más interesante. A este tipo de minería de datos se le conoce como minería de flujo de datos [5].

La minería de flujo de datos tiene en cuenta varios factores que hacen que la extracción de conocimiento en este tipo de datos sea un desafío en comparación con la minería de datos tradicional, como por ejemplo la actualización continua del modelo de aprendizaje o la necesidad de desechar información antigua [6], [5]. Además, muchos sensores y fuentes de datos poseen una tasa de refresco muy elevada (del orden de Khz) que implican además un aprendizaje lo más rápido posible [7].

La minería de patrones emergentes (EPM) [8], [9] es una tarea de minería de datos encuadrada dentro del marco de tareas denominado “descubrimiento de reglas descriptivas mediante aprendizaje supervisado” (SDRD) [10]. El principal objetivo de la tarea es la extracción de patrones descriptivos

cuyo soporte varíe significativamente de un conjunto de datos (o clase) a otro. Esto quiere decir que EPM se encuentra a medio camino entre las inducciones descriptiva y predictiva ya que se pretende describir relaciones entre los datos utilizando para ello aprendizaje supervisado. Las principales finalidades de esta tarea son la descripción de las características discriminativas entre clases o la descripción de tendencias emergentes. No obstante, a pesar de las claras capacidades descriptivas de la tarea, esta se ha utilizado ampliamente en la literatura como un clasificador, aplicándose con éxito en campos como la Química [11], [12], Bioinformática [13], [14] o Medicina [15], [16], entre otros [17]. No obstante, un nuevo enfoque basado en el uso de sistemas difuso evolutivos (EFSs) [18] ha sido desarrollado recientemente con propuestas capaces de extraer conocimiento con un buen balance entre la capacidad descriptiva de las reglas y su fiabilidad [19], [9], [20].

En este trabajo se presenta una primera propuesta para la extracción de patrones emergentes de calidad en entornos de minería de flujo de datos denominado SE2P (*Stream Extraction of Emerging Patterns*). Este algoritmo se basa principalmente en el empleo de dos fases: una fase *online* en la que se almacena la información hasta obtener un bloque de datos con un tamaño determinado y una fase *offline* basada en un sistema difuso evolutivo (EFS) multi-objetivo capaz de extraer conocimiento de las características discriminativas entre clases con un buen balance entre capacidad descriptiva y fiabilidad sobre dicho bloque de datos.

El trabajo se estructura de la siguiente manera: en la Sección II se introduce el problema y, en concreto, la definición y características de EPM y de la minería de flujo de datos a lo largo de la literatura. A continuación, en la Sección III se presenta el enfoque de extracción de conocimiento propuesto y en la Sección IV se muestra un estudio experimental para la validación de la calidad del conocimiento extraído. Por último, se presentan las conclusiones extraídas junto a los posibles trabajos futuros.

## II. PRELIMINARES

En esta sección se revisan los conceptos básicos referentes a EPM y la minería de flujo de datos. En primer lugar se presenta la definición de EPM así como sus objetivos principales. A continuación, se define la minería de flujo de datos junto a una breve descripción de los diferentes enfoques utilizados. Por último, se presentan las principales medidas de calidad

empleadas en EPM y cómo son empleadas en SE2P para la minería de flujo de datos.

### II-A. Minería de patrones emergentes

La minería de patrones emergentes fue definida por Dong y Li [8], [9] como:

“Sea un patrón  $X$  cualquiera, y sea  $\rho > 1$  un valor de umbral,  $X$  se denominará como emergente si y solo si su índice de crecimiento entre dos conjuntos de datos  $D_1$  y  $D_2$  es mayor que  $\rho$ .”

Este índice de crecimiento (GR) es definido con una función representada en la Ecuación 1.

$$GR(X) = \begin{cases} 0, & \text{Si } Sop_1(X) = Sop_2(X) = 0, \\ \infty, & \text{Si } Sop_1(X) = 0 \wedge Sop_2(X) \neq 0, \\ \frac{Sop_2(X)}{Sop_1(X)}, & \text{en otro caso} \end{cases} \quad (1)$$

donde  $Sop_i(X)$  es el soporte del patrón  $X$  en el conjunto de datos  $i$ .

Los propósitos principales para los que fue definida la tarea son:

- La descripción de las diferencias características entre clases o conjuntos de datos.
- La descripción de tendencias emergentes.
- La detección de diferencias entre múltiples variables.

En concreto, nuestra propuesta se centrará en el primer objetivo, es decir, lo que buscamos son diferencias características entre las clases de un flujo de datos a lo largo del tiempo. Habitualmente, estos patrones se presentan al experto en forma de reglas con el siguiente formato [21]:

$$R : Cond \rightarrow Clase \quad (2)$$

donde  $Cond$  es un conjunto de características, normalmente en forma de pares atributo-valor y  $Clase$  es el valor de la variable objetivo o de interés.

La principal dificultad que posee la extracción de estos patrones se encuentra en la misma definición de patrón emergente. El GR se define en función de un ratio entre soportes, lo cual propicia que el espacio de los patrones emergentes no sea convexo [22]. Esto quiere decir que patrones más específicos, y por tanto, con menor soporte, puedan poseer valores de GR más elevados que aquellos cuyos soportes sean más altos. Es por esta razón que se han definido a lo largo de la literatura diferentes tipos de patrones emergentes cuyas restricciones permiten una mayor facilidad de extracción, como los patrones *Jumping* o los patrones emergentes  $\chi^2$ , entre otros [23], [24], [25], [9]. Asimismo, se han desarrollado diferentes técnicas algorítmicas para la extracción de estos patrones encuadradas en cuatro categorías diferentes [9]. A pesar del amplio desarrollo de la tarea, la gran mayoría de algoritmos han sido desarrollados como clasificadores, ignorando las cualidades descriptivas de la tarea. Sin embargo, en los últimos años se ha desarrollado un enfoque basado en EFSs, donde destaca el algoritmo MOEA-EFEP [20], cuyos resultados poseen un buen balance entre las cualidades descriptivas y la fiabilidad de las reglas.

### II-B. Minería de flujo de datos

Un flujo de datos se define como una secuencia ordenada y potencialmente infinita de ejemplos que llegan al sistema a lo largo del tiempo a una velocidad que puede ser variable [26]. Esta definición tan simple de un flujo de datos trae consigo una gran variedad de diferencias respecto a la minería de datos tradicional, donde se destaca [5]:

- No se puede almacenar toda la información en memoria. Al ser potencialmente de tamaño infinito hay que buscar estrategias para procesar y descartar los datos.
- Todos los datos no se encuentran disponibles en el momento del aprendizaje. Los datos van llegando a lo largo del tiempo y es el modelo el que tiene que aprender conforme los datos lleguen, es decir, el modelo debe de adaptarse a lo largo del tiempo.
- Como el flujo es generado por una fuente a lo largo del tiempo, el fenómeno que subyace en la generación de dichos datos suele cambiar con mayor o menor frecuencia. A este hecho se le denomina en la literatura como cambio de concepto [27]. Esto quiere decir que el modelo aprendido con los datos en un instante  $t$ , si se produce un cambio de concepto, no será válido para los datos en el instante  $t + x$ .
- Esta velocidad de llegada es, normalmente, alta respecto a la capacidad de procesamiento que se posee. Por lo tanto, se busca que el algoritmo de aprendizaje sea capaz de aprender lo más rápido posible con el fin de evitar el encolamiento de las instancias.

Teniendo en cuenta estas características, las instancias que llegan al sistema se pueden procesar de dos formas diferentes [5]:

- Online. Las instancias llegan una a una y son procesadas por el algoritmo de aprendizaje tan pronto estén disponibles.
- Por bloques. Las instancias son almacenadas hasta obtener un bloque de datos de un tamaño predeterminado y donde todo el bloque es procesado a la vez por el algoritmo de aprendizaje.

Una vez se ha elegido la metodología de procesamiento de los datos, es necesario determinar la estrategia de aprendizaje del método. Entre las técnicas más utilizadas para el aprendizaje en minería de flujo de datos destacan [28]:

- Detectores de cambio de concepto [29]. Son métodos externos al algoritmo de aprendizaje que calculan diferentes propiedades del flujo de datos para detectar cambios. Normalmente poseen dos niveles: un nivel de alerta en donde el cambio empieza a ocurrir, donde solo se aprende usando los datos más recientes; y un nivel de alarma indicando un cambio severo donde el clasificador se reemplaza.
- Ventanas deslizantes [30]. Se almacenan en un *buffer* de memoria las instancias más recientes, deshaciéndose de aquellas más antiguas que no caben en dicho *buffer*. Esto permite al método aprender únicamente de las instancias más recientes en el flujo.



- Ensemble [31]. En donde se utilizan diferentes clasificadores que permiten hacer un seguimiento del flujo de datos. Existen actualmente dos estrategias principales: aprender un nuevo método y añadirlo al ensemble, descartando métodos antiguos si es necesario, o bien mediante un esquema de pesos en los diferentes clasificadores en función de su rendimiento.

### II-C. Medidas de calidad

En minería de datos tradicional, la calidad de un modelo se determina mediante diferentes mecanismos como por ejemplo la validación cruzada [32]. Sin embargo, muchos de estos mecanismos requieren del uso del conjunto de datos completo para poder realizar una evaluación correcta. Esto es imposible en minería de flujo de datos porque no poseemos el conjunto de datos al completo. Por lo que es necesario el uso de técnicas diferentes para la evaluación de los modelos.

Uno de los esquemas de evaluación más utilizado es el denominado *test-then-train* [33]. En este esquema, cuando una instancia o bloque de datos llega al sistema sirve para evaluar el modelo actual o hacer una predicción sobre la instancia concreta o el bloque de datos. Una vez se realiza este proceso, dicha instancia o bloque pasa a entrenar el modelo actual.

En EPM, la medida más importante es el GR, pues es la métrica que define la tarea. No obstante, es necesario determinar diferentes aspectos tales como generalidad, interés o fiabilidad [9], claves para la correcta extracción de reglas interpretables y precisas. La tarea fue concebida inicialmente para el análisis de problemas entre dos clases o conjuntos de datos. Sin embargo, la tarea puede ser fácilmente extendida a problemas multiclase mediante estrategias como *One vs All* (OVA) [34] donde la clase positiva es la que se encuentra descrita en el consecuente de la regla y la negativa el resto de clases del problema.

Cuadro I  
MATRIZ DE CONFUSIÓN PARA UNA REGLA EN EPM.

Clase real	Clase predicha	
	Positive	Negative
Positive	$p = tp$	$\bar{p} = fn$
Negative	$n = fp$	$\bar{n} = tn$

En la Tabla I se puede observar la matriz de confusión, donde:  $p$  representa el número de ejemplos correctamente cubiertos,  $\bar{p}$  el número de ejemplos de la clase no cubiertos,  $n$  el número de ejemplos cubiertos incorrectamente, y  $\bar{n}$  el número de ejemplo correctamente no cubiertos.

Las medidas de calidad más utilizadas en EPM son las descritas a continuación [9]:

- Growth Rate (GR). Definida en la Ecuación 1, mide el poder discriminativo de una regla.
- Confianza (Conf). Se define como el ratio de la capacidad predictiva de la regla para la clase positiva [35].

$$Conf(R) = \frac{p}{p+n} \quad (3)$$

- Atipicidad (Atip). Esta medida híbrida muestra el balance existente entre generalidad y ganancia de precisión de la regla [21].

$$Atip(R) = \frac{p+n}{P+N} \left( \frac{p}{p+n} - \frac{P}{P+N} \right) \quad (4)$$

El dominio de esta medida tiene una dependencia directa con el porcentaje de la clase a medir, por lo tanto, para realizar comparaciones es necesario normalizar esta medida. Esta normalización se ha llevado a cabo de la siguiente manera:

$$Atip_{Norm}(R) = \frac{Atip(R) - \left(\frac{P}{T} \left(0 - \frac{P}{T}\right)\right)}{\left(\frac{P}{T} \left(1 - \frac{P}{T}\right)\right) - \left(\frac{P}{T} \left(0 - \frac{P}{T}\right)\right)} \quad (5)$$

- Tasa de falsos positivos (FPR). Mide el porcentaje de ejemplos incorrectamente cubiertos respecto al total de ejemplos de la clase negativa. Esta medida debe ser minimizada para la obtención de reglas precisas [36].

$$FPR(R) = \frac{n}{N} \quad (6)$$

- Tasa de verdaderos positivos (TPR). Mide el porcentaje de ejemplos correctamente cubiertos respecto al número total de ejemplos de la clase positiva [37].

$$TPR(R) = \frac{p}{P} \quad (7)$$

- Número de reglas. Mide la cantidad de reglas extraídas.
- Número de variables. Mide el número medio de variables que se obtienen en el conjunto de reglas.

### III. SE2P: STREAM EXTRACTION OF EMERGING PATTERNS

Esta sección presenta la propuesta algorítmica para la extracción de patrones emergentes descriptivos para minería de flujo de datos llamado SE2P.

SE2P utiliza un enfoque basado en dos fases online/offline utilizando para ello el esquema de procesamiento de instancias basado en bloques. Esto implica que la fase online en un primer lugar agrupará instancias provenientes del stream hasta que se alcance el número de instancias determinado por el tamaño de bloque. Cuando hay un bloque de datos disponible, la fase offline ejecutará el núcleo de SE2P, el cual es un EFS multi-objetivo basado en el enfoque NSGA-II [38] para la extracción de un conjunto de reglas que representen las características discriminativas de las diferentes clases que se encuentren en dicho bloque. Es importante destacar que la estrategia de aprendizaje de SE2P se basa en una modificación del esquema de ventanas deslizantes donde se almacenan los modelos de reglas obtenidos previamente más una función de evaluación en el proceso evolutivo que permite el uso de esta estructura con el objetivo de adaptarse a los cambios de concepto.

Este algoritmo evolutivo utiliza una codificación “cromosoma = regla” donde se representa tanto el antecedente como el consecuente de la regla, lo que permite la extracción de reglas de todas las posibles clases en una única ejecución. La única representación disponible en este método es la forma

normal disyuntiva (DNF), ya que se ha demostrado que se obtienen mejores resultados que con otras representaciones [39]. La Figura 1 presenta una regla DNF, representada en el genotipo por un vector binario. Es importante destacar que para variables numéricas se emplea el número de conjuntos difusos correspondientes a etiquetas lingüísticas que se definen por funciones de pertenencia triangulares uniformes.

$$\begin{array}{c}
 \left| \begin{array}{c|c|c|c} x_1 & x_2 & x_3 & x_4 \\ \hline 101 & 111 & 10000 & 000 \end{array} \right| \begin{array}{c} \text{Genotipo} \\ \hline \text{Class} \\ \hline 1 \end{array} \\
 \downarrow \\
 \text{Genotipo} \\
 SI(x_1 = (LL_1^1 \vee LL_1^3)) \wedge (x_3 = Cat_3^1) \text{ ENTONCES } (x_{obj} = Positiva)
 \end{array}$$

Figura 1. Representación de una regla DNF en EvAEP.

### III-A. Operador de inicialización

SE2P utiliza un operador de inicialización sesgada basado en el conocimiento previo con el fin de poder actualizarlo con los nuevos datos. Este operador añade el modelo de reglas extraído del bloque de datos anterior a la población inicial ( $P_0$ ) mientras que el resto de individuos son inicializados de manera completamente aleatoria, pero controlando la inicialización de, como máximo, el 25% de sus variables en el 75% de individuos de esta población. Esto permite la obtención de individuos con gran generalidad al proceso evolutivo.

### III-B. Operadores genéticos

La población de la siguiente generación es obtenida mediante la aplicación de distintos operadores genéticos: operador de selección por torneo binario [40], un operador de cruce multipunto [41] y un operador de mutación sesgada empleado por primera vez en un algoritmo de descubrimiento de subgrupos en [42].

Asimismo, SE2P utiliza un operador de reinicialización con el fin de evitar el estancamiento de la población en un óptimo local. Esta reinicialización se lleva a cabo mediante la utilización de un operador de token competition [43] con el que se eliminan reglas solapadas. A continuación, el resto de individuos se genera aleatoriamente.

### III-C. Función de evaluación

Uno de los aspectos fundamentales en la minería de flujo de datos es la necesidad de adaptar el modelo en función de los datos que van llegando. Como hemos visto anteriormente, el fenómeno subyacente en los datos puede variar a lo largo del tiempo, pudiendo invalidar todo el conocimiento previo. Por lo tanto SE2P utiliza un esquema de ventana deslizante con pesos en donde se almacenan únicamente los  $n$  últimos conjuntos de reglas extraídos. Con esta estructura, la función que se utilizará para determinar la calidad de cada objetivo en SE2P para una regla  $R_i$  viene dada por la Ecuación 8.

$$\text{Fitness}_t^k(R_i) = QM_t^k(R_i) \cdot \left[ 1 - \sum_{j=t-n}^t SW(R_i, j) \cdot 2^{-(t-j)} \right] \quad (8)$$

donde  $QM_t^k(R_i)$  es el valor de la medida de calidad usada como objetivo  $k$  en el bloque de datos  $t$  actual,  $SW(R_i, j)$  es una función que devuelve cero si  $R_i$  se encuentra en el conjunto de reglas devuelto para el bloque  $j$  o uno en caso contrario. El objetivo de esta función de evaluación no es otro que la penalización de aquellas reglas que no definen el fenómeno subyacente en los datos, representado por las reglas extraídas anteriormente. Esto se debe a que el cambio normalmente se produce de manera gradual, por lo que el conocimiento previo sigue siendo relevante hasta que el nuevo prevalece.

### III-D. Esquema de funcionamiento

El proceso de ejecución de SE2P es el siguiente: una vez se ha obtenido un bloque de datos, se lanza la fase de aprendizaje offline. En un primer lugar, siguiendo el esquema *test-then-train* se evaluará el modelo de reglas extraído en el bloque anterior. Una vez evaluado el modelo de reglas, dicho bloque de datos pasa a ser un conjunto de entrenamiento. Es importante destacar que, al no existir un modelo de reglas previo, el primer bloque pasa a ser directamente de entrenamiento. Por lo tanto, las evaluaciones se realizan a partir del segundo bloque.

A continuación, el EFS multi-objetivo se ejecuta, comenzando con la aplicación del operador de inicialización sesgada basada en conocimiento previo para generar  $P_0$ . Después, el proceso evolutivo da comienzo, ejecutándose durante  $g$  generaciones o hasta que un nuevo bloque de datos esté disponible. Dentro de este proceso evolutivo se aplicarán los operadores genéticos, obteniendo una población de descendientes  $Q_g$  de igual tamaño que la población actual. A continuación ambas poblaciones se unen en  $U_g$ , se evalúan aquellos individuos no evaluados y se obtiene la población de la siguiente generación mediante la ordenación por frentes de dominancia propia del algoritmo NSGA-II. Por último, se analiza el estancamiento de la población, donde se comprueba si la población actual no ha cubierto ejemplos nuevos del bloque durante un 25% del total de generaciones. El operador de reinicialización se aplicará en caso de que la población se estanque.

Una vez finalizado el proceso evolutivo, el algoritmo aplicará el operador de token competition [43] para eliminar aquellas reglas redundantes y el resultado de este procedimiento será el devuelto al usuario.

## IV. ESTUDIO EXPERIMENTAL

En este trabajo se presenta un estudio preliminar de una primera propuesta para la extracción de patrones emergentes con un buen balance entre la capacidad descriptiva de las reglas extraídas y la fiabilidad de las mismas dentro de la minería de flujo de datos. En concreto, se abordará el tratamiento de Big Data mediante técnicas de minería de flujos de datos. Para ello se ha simulado un flujo de datos mediante la herramienta de minería de datos MOA [44]. Las características de los conjuntos de datos utilizados como por ejemplo el número de instancias totales, número de variables y número de clases se presentan en la Tabla II.



Cuadro II

CONJUNTOS DE DATOS UTILIZADOS EN EL ESTUDIO EXPERIMENTAL.

Nombre	# Instancias	# Variables	# Clases
Air	539395	7	2
Elec	45312	7	2
forest	581012	54	7
Higgs	1100000	28	2
Susy	500000	18	2

Los parámetros utilizados por SE2P en este estudio experimental se muestran en la Tabla III, los parámetros utilizados son similares a los utilizados por EFSs desarrollados para EPM sobre datos estáticos [20]. Sin embargo, uno de los parámetros más importantes para determinar el rendimiento de SE2P es el tamaño del bloque de datos que se procesará. En este trabajo se van a seleccionar tres tamaños de bloque diferentes: 1500, 2500 y 5000 instancias por bloque con el objetivo de determinar el más apropiado.

Cuadro III

PARÁMETROS UTILIZADOS POR SE2P EN EL ESTUDIO EXPERIMENTAL.

Parámetro	Valor
Etiquetas lingüísticas	3
Número de generaciones máximas	60
Tamaño de población	50
Probabilidad de cruce	0.7
Probabilidad de mutación	0.1
Tamaño de ventana temporal	5

Cuadro IV

RESULTADOS MEDIOS OBTENIDOS POR SE2P EN LOS FLUJOS DE DATOS ANALIZADOS.

Nombre	Tam. bloque	$n_p$	$n_v$	ATIP	CONF	GR	TPR	FPR	Tiempo ejec. (ms)
Air	1500	2,006	<b>2,539</b>	<b>0,588</b>	<b>0,594</b>	<b>0,953</b>	<b>0,521</b>	0,346	<b>400,402</b>
	2500	<b>2,000</b>	2,539	0,584	0,581	0,914	0,498	0,330	473,280
	5000	<b>2,000</b>	2,580	0,575	0,541	0,873	0,477	<b>0,327</b>	1159,472
Elec	1500	2,000	2,259	0,657	0,688	0,966	0,583	0,269	<b>433,586</b>
	2500	<b>1,941</b>	<b>2,088</b>	0,659	<b>0,700</b>	<b>0,971</b>	<b>0,612</b>	<b>0,294</b>	557,235
	5000	2,000	2,875	<b>0,661</b>	0,687	0,938	0,583	0,262	581,125
forest	1500	<b>4,054</b>	<b>9,107</b>	<b>0,770</b>	<b>0,519</b>	<b>0,969</b>	<b>0,799</b>	<b>0,241</b>	<b>1692,702</b>
	2500	4,134	9,578	0,739	0,495	0,948	0,764	0,263	1915,446
	5000	4,252	9,184	0,693	0,437	0,914	0,730	0,307	2616,087
Higgs	1500	2,011	<b>7,640</b>	0,524	0,549	0,913	0,475	0,426	<b>263,109</b>
	2500	2,013	8,237	0,526	<b>0,550</b>	0,960	<b>0,477</b>	0,426	337,272
	5000	<b>2,007</b>	9,904	<b>0,526</b>	0,536	<b>0,992</b>	0,433	<b>0,380</b>	436,454
Susy	1500	2,006	<b>7,081</b>	<b>0,622</b>	0,674	<b>1,000</b>	<b>0,516</b>	<b>0,272</b>	<b>212,349</b>
	2500	<b>2,004</b>	7,454	0,604	<b>0,692</b>	<b>1,000</b>	0,486	0,277	257,945
	5000	2,005	7,821	0,596	0,681	<b>1,000</b>	0,487	0,296	315,184

En la Tabla IV se presentan los resultados medios obtenidos por SE2P a lo largo de los diferentes flujos de datos analizados. Es importante remarcar que, debido al funcionamiento de SE2P, estos resultados medios se han obtenido usando  $n_b - 1$  bloques, siendo  $n_b$  el número total de bloques analizados. A continuación se muestra un análisis de cada una de las diferentes medidas de calidad analizadas:

- Número de reglas y variables. En general el número de reglas obtenido es muy bajo. Se destaca que el número de instancias por bloque no influye significativamente en estos resultados. Sin embargo, se puede observar que el número de variables es en algunos casos elevado, llevando el modelo extraído a una nivel de complejidad mayor. Sin embargo, en líneas generales, el modelo extraído es simple.

- Atipicidad. Esta medida, que mide el interés de las reglas extraídas, nos indica que en general las reglas obtenidas son interesantes, obteniéndose mejores resultados en bloques de 1500 instancias.
- Confianza. En esta medida se puede observar una amplia variabilidad en los resultados, donde el mejor resultado se obtiene con tamaños de bloque de 2500 en tres de los cinco conjuntos analizados. No obstante, el nivel de confianza es aceptable en los diferentes tamaños de bloque.
- GR. En esta medida se representa el porcentaje de patrones extraídos que son patrones emergentes. Como se puede observar, en general se extraen reglas emergentes y que por tanto poseen altas capacidades discriminativas, independientemente del tamaño de bloque escogido.
- Balance TPR-FPR. En estos resultados se puede observar que la generalidad de las reglas medidas como TPR es bastante elevada. Sin embargo, a pesar de que los niveles de FPR son elevados, la diferencia entre ambas métricas nos permite poder decir que los resultados obtenidos poseen, en general, un buen balance entre la generalidad y la precisión. También es importante destacar que los resultados son mejores a menor tamaño de bloque.
- Tiempo de ejecución. En cuanto al tiempo de ejecución del algoritmo se puede observar que, obviamente, el tiempo medio de procesamiento de un bloque es menor en función del tamaño de bloque. Además, se destaca que el tiempo de ejecución es lo suficientemente rápido para el procesamiento de flujos de datos en donde se pueda procesar un bloque de datos cada segundo, lo cual es bastante aceptable.

## V. CONCLUSIONES

En este trabajo se ha presentado un estudio preliminar de un primer enfoque la extracción de patrones emergentes para minería de flujo de datos. Este algoritmo se basa en el procesamiento de las instancias por bloques de datos de tamaño fijo en donde se ejecuta un algoritmo evolutivo multi-objetivo por cada bloque con el objetivo de extraer patrones emergentes que describan las características discriminativas de las diferentes clases del problema.

Los resultados del estudio realizado demuestran unos resultados muy prometedores y abren una línea de investigación donde se necesita implementar nuevas técnicas para mejorar los resultados actuales y los tiempos de ejecución a fin de poder procesar flujos de datos más veloces.

## AGRADECIMIENTOS

Este trabajo ha sido subvencionado por el Ministerio de Economía y Competitividad bajo el proyecto TIN2015-68454-R y el contrato predoctoral FPI referencia BES-2016-077738 asociado al mismo (Fondos FEDER).

## REFERENCIAS

- [1] A. Fernández, S. Rfo, V. López, A. Bawakid, M. del Jesus, J. Benítez, and F. Herrera, "Big Data with Cloud Computing: An Insight on the Computing Environment, MapReduce and Programming Frameworks," *WIREs Data Mining and Knowledge Discovery*, vol. 5, no. 4, pp. 380–409, 2014.
- [2] T. Kraska, "Finding the Needle in the Big Data Systems Haystack," *IEEE Internet Computing*, vol. 17, no. 1, pp. 84–86, 2013.
- [3] X. Wu, X. Zhu, G.-Q. Wu, and W. Ding, "Data mining with big data," *IEEE transactions on knowledge and data engineering*, vol. 26, no. 1, pp. 97–107, 2014.
- [4] I. Žliobaitė, M. Pechenizkiy, and J. Gama, "An overview of concept drift applications," in *Big Data Analysis: New Algorithms for a New Society*. Springer, 2016, pp. 91–114.
- [5] J. Gama, *Knowledge discovery from data streams*. CRC Press, 2010.
- [6] A. Bifet, "Adaptive learning and mining for data streams and frequent patterns," Ph.D. dissertation, Universitat Politècnica de Catalunya, 2009.
- [7] D. Han, C. Giraud-Carrier, and S. Li, "Efficient mining of high-speed uncertain data streams," *Applied Intelligence*, vol. 43, no. 4, pp. 773–785, 2015.
- [8] G. Z. Dong and J. Y. Li, "Efficient Mining of Emerging Patterns: Discovering Trends and Differences," in *Proc. of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM Press, 1999, pp. 43–52.
- [9] A. M. García-Vico, C. J. Carmona, D. Martín, M. García-Borroto, and M. J. del Jesus, "An overview of emerging pattern mining in supervised descriptive rule discovery: Taxonomy, empirical study, trends and prospects," *WIREs: Data Mining and Knowledge Discovery*, vol. 8, no. 1, 2018.
- [10] P. Kralj-Novak, N. Lavrac, and G. I. Webb, "Supervised Descriptive Rule Discovery: A Unifying Survey of Constraint Set, Emerging Pattern and Subgroup Mining," *Journal of Machine Learning Research*, vol. 10, pp. 377–403, 2009.
- [11] R. Sherhod, V. J. Gillet, T. Hanser, P. N. Judson, and J. D. Vessey, "Toxicological knowledge discovery by mining emerging patterns from toxicity data," *Journal of Chemical Information and Modeling*, vol. 5, no. S-1, p. 9, 2013.
- [12] A. Lepailleur, G. Poezevara, and R. Bureau, "Automated detection of structural alerts (chemical fragments) in (eco) toxicology," *Computational and structural biotechnology journal*, vol. 5, no. 6, pp. 1–8, 2013.
- [13] M. Piao, H. G. Lee, G. Y. Sohn, G. Pok, and K. H. Ryu, "Emerging patterns based methodology for prediction of patients with myocardial ischemia," in *Proc. of the 6th International Conference on Fuzzy Systems and Knowledge Discovery*. IEEE, 2009, pp. 174–178.
- [14] G. Tzanis, I. Kavakiotis, and I. P. Vlahavas, "Polya-icp: A data mining method for the effective prediction of polyadenylation sites," *Expert Systems with Applications*, vol. 38, no. 10, pp. 12398–12408, 2011.
- [15] P. W. Angriyasa, Z. Rustam, and W. Sadewo, "Non-invasive intracranial pressure classification using strong jumping emerging patterns," in *Proc. of the 2011 International Conference on Advanced Computer Science and Information System (ICACSIS)*. IEEE, 2011, pp. 377–380.
- [16] Y. Yu, K. Yan, X. Zhu, and G. Wang, "Detecting of PIU Behaviors Based on Discovered Generators and Emerging Patterns from Computer-Mediated Interaction Events," in *Proc. of the 15th International Conference on Web-Age Information Management*, ser. LNCS, vol. 8485. Elsevier, 2014, pp. 277–293.
- [17] G. Li, R. Law, H. Q. Vu, J. Rong, and X. R. Zhao, "Identifying emerging hotel preferences using emerging pattern mining technique," *Tourism management*, vol. 46, pp. 311–321, 2015.
- [18] F. Herrera, "Genetic fuzzy systems: taxonomy, current research trends and prospects," *Evolutionary Intelligence*, vol. 1, pp. 27–46, 2008.
- [19] A. M. García-Vico, J. Montes, J. Aguilera, C. J. Carmona, and M. J. del Jesus, "Analysing Concentrating Photovoltaics Technology through the use of Emerging Pattern Mining," in *Proc. of the 11th International Conference on Soft Computing Models in Industrial and Environmental Applications*. Springer, 2016, pp. 1–8.
- [20] A. M. García-Vico, C. J. Carmona, P. González, and M. J. del Jesus, "Moea-efep: Multi-objective evolutionary algorithm for extracting fuzzy emerging patterns," *IEEE Transactions on Fuzzy Systems*, In Press.
- [21] C. J. Carmona, M. J. del Jesus, and F. Herrera, "A Unifying Analysis for the Supervised Descriptive Rule Discovery via the Weighted Relative Accuracy," *Knowledge-Based Systems*, vol. 139, pp. 89–100, 2018.
- [22] L. Wang, H. Zhao, G. Dong, and J. Li, "On the complexity of finding emerging patterns," in *Proc. of the 28th Annual International Computer Software and Applications Conference*, vol. 2, 2004, pp. 126–129.
- [23] G. Z. Dong, J. Y. Li, and X. Zhang, "Discovering jumping emerging patterns and experiments on real datasets," in *Proc. on International Database Conference Heterogeneous and Internet Databases*, 1999, pp. 155–168.
- [24] H. Fan and K. Ramamohanarao, "Noise Tolerant Classification by Chi Emerging Patterns," in *Proc. of the 8th Pacific-Asia Conference on Knowledge Discovery and Data Mining*, ser. LNCS, vol. 3056. Springer, 2004, pp. 201–206.
- [25] K. Ramamohanarao and H. Fan, "Patterns Based Classifiers," *World Wide Web*, vol. 10, no. 1, pp. 71–83, 2007.
- [26] M. M. Gaber, "Advances in data stream mining," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 2, no. 1, pp. 79–85, 2012.
- [27] J. a. Gama, I. Žliobaitė, A. Bifet, M. Pechenizkiy, and A. Bouchachia, "A survey on concept drift adaptation," *ACM Comput. Surv.*, vol. 46, no. 4, pp. 44:1–44:37, 2014.
- [28] S. Ramírez-Gallego, B. Krawczyk, S. García, M. Wozniak, and F. Herrera, "A survey on data preprocessing for data stream mining: Current status and future directions," *Neurocomputing*, vol. 239, pp. 39–57, 2017.
- [29] R. M. Vallim and R. F. De Mello, "Proposal of a new stability concept to detect changes in unsupervised data streams," *Expert Systems with Applications*, vol. 41, no. 16, pp. 7350–7360, 2014.
- [30] J. Shan, J. Luo, G. Ni, Z. Wu, and W. Duan, "Cvs: fast cardinality estimation for large-scale data streams over sliding windows," *Neuro-computing*, vol. 194, pp. 107–116, 2016.
- [31] B. Krawczyk, L. L. Minku, J. a. Gama, J. Stefanowski, and M. Woźniak, "Ensemble learning for data stream analysis: A survey," *Information Fusion*, vol. 37, pp. 132–156, 2017.
- [32] N. Japkowicz and M. Shah, *Evaluating learning algorithms: a classification perspective*. Cambridge University Press, 2011.
- [33] A. Wald, *Sequential analysis*. Courier Corporation, 1973.
- [34] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, and F. Herrera, "An overview of ensemble methods for binary classifiers in multi-class problems: Experimental study on one-vs-one and one-vs-all schemes," *Pattern Recognition*, vol. 44, no. 8, pp. 1761–1776, 2011.
- [35] U. M. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "From data mining to knowledge discovery: an overview," in *Advances in knowledge discovery and data mining*. AAAI/MIT Press, 1996, pp. 1–34.
- [36] D. Gamberger and N. Lavrac, "Expert-Guided Subgroup Discovery: Methodology and Application," *Journal Artificial Intelligence Research*, vol. 17, pp. 501–527, 2002.
- [37] W. Kloesgen, "Explora: A Multipattern and Multistrategy Discovery Assistant," in *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence, 1996, pp. 249–271.
- [38] K. Deb, A. Pratap, S. Agrawal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.
- [39] A. García-Vico, C. J. Carmona, and M. J. del Jesus, "Análisis de diferentes tipos de reglas en sistemas difusos evolutivos para minería de patrones emergentes," in *Proc. of the XII Spanish Conference on Metaheuristics, Evolutionary and Bioinspired Algorithms (MAEB 2017)*, 2017, p. 876–885.
- [40] B. L. Miller and D. E. Goldberg, "Genetic Algorithms, Tournament Selection, and the Effects of Noise," *Complex System*, vol. 9, pp. 193–212, 1995.
- [41] J. H. Holland, "Adaptation in natural and artificial systems," *University of Michigan Press*, 1975.
- [42] C. J. Carmona, P. González, M. J. del Jesus, and F. Herrera, "NMEEF-SD: Non-dominated Multi-objective Evolutionary algorithm for Extracting Fuzzy rules in Subgroup Discovery," *IEEE Transactions on Fuzzy Systems*, vol. 18, no. 5, pp. 958–970, 2010.
- [43] K. S. Leung, Y. Leung, L. So, and K. F. Yam, "Rule Learning in Expert Systems Using Genetic Algorithm: 1, Concepts," in *Proc. of the 2nd International Conference on Fuzzy Logic and Neural Networks*, K. Jizuka, Ed., 1992, pp. 201–204.
- [44] A. Bifet, G. Holmes, R. Kirkby, and B. Pfahringer, "MOA: massive online analysis," *Journal of Machine Learning Research*, vol. 11, pp. 1601–1604, 2010. [Online]. Available: <https://moa.cms.waikato.ac.nz/>



# Segmentación de mercado explicable sobre datos de alta dimensión

Carlos Eiras-Franco  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
carlos.eiras.franco@udc.es

Bertha Guijarro-Berdiñas  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
cibertha@udc.es

Amparo Alonso-Betanzos  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
ciamparo@udc.es

Antonio Bahamonde  
Universidad de Oviedo  
Gijón, España  
abahamonde@uniovi.es

**Resumen**—Obtener información relevante de la gran cantidad de datos que se generan en las interacciones de un mercado o, en general, de un conjunto de datos diádicos, es un amplio problema que despierta gran interés académico y en la industria. Por otra parte, la interpretabilidad de los algoritmos de aprendizaje máquina está adquiriendo relevancia hasta el punto de ser requerida legalmente, lo que dispara la necesidad de contar con algoritmos con estas características. En este trabajo proponemos una medida de calidad que tiene en cuenta el nivel de interpretabilidad de un resultado. Presentamos, además, un algoritmo de agrupamiento sobre datos diádicos que ofrece resultados con el nivel de interpretabilidad que desee el usuario y que es capaz de manejar grandes volúmenes de datos. Detallamos experimentos que avalan tanto la precisión de los resultados obtenidos, comparable a métodos tradicionales, como su escalabilidad.

**Index Terms**—segmentación de mercado, interpretabilidad, explicabilidad, escalabilidad, aprendizaje automático, big data

## I. INTRODUCCIÓN

Los datos obtenidos al monitorizar el funcionamiento de un mercado son, en su mayoría, diádicos, es decir, representan la relación entre dos entidades, ya sean estas usuarios y productos, compradores y vendedores u otra pareja de agentes. Más generalmente, los datos diádicos [1] recogen información sobre la interacción de dos entidades de cualquier ámbito y son prevalentes en problemas tan comunes como los sistemas recomendadores [2], lingüística computacional, recuperación de información y aprendizaje de preferencias [3], además de estar presentes en campos más específicos como la corrección automática de exámenes [4].

Un problema tradicional a tratar sobre datos de este tipo consiste en obtener agrupaciones de entidades con un comportamiento similar, dando lugar a un modelado de mayor nivel del entorno estudiado. De esta manera se podría, por ejemplo a partir de los datos de un recomendador de libros, buscar conjuntos de libros que atraen a usuarios similares o conjuntos de usuarios que tienen gustos parecidos respecto a la lectura.

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad (proyectos de investigación TIN 2015-65069-C2, tanto 1-R como 2-R y Red Española de Big Data y Análisis de datos escalable, TIN2016-82013-REDT), por la Xunta de Galicia (GRC2014/035 y ED431G/01) y por Fondos de Desarrollo Regional de la Unión Europea.

El estudio de los mercados con el objetivo de identificar subconjuntos de actores que se comportan como mercados más pequeños y homogéneos es la meta de la segmentación de mercados [5]. La información obtenida a partir de estas agrupaciones que se comportan de manera homogénea permite a las empresas hacer campañas de marketing dirigido a medida de cada grupo, aumentando así su efectividad y disminuyendo costes [6]. Esta información es, por tanto, una ventaja codiciada por las empresas, pero resulta complicada de obtener en la práctica aún cuando se dispone de abundantes datos.

Por otra parte, que los resultados obtenidos de la segmentación de mercados sean comprensibles por un gestor humano es un factor esencial que está atrayendo mucha atención recientemente. El concepto de interpretabilidad se refiere a esta característica, aunque no se trata de un concepto monolítico sino que, de acuerdo a [7], refleja distintas ideas. Idealmente, el modelo obtenido debe:

1. permitir a un supervisor interpretar sus resultados de manera que pueda verificar que los objetivos del modelo están alineados con los deseados (p.e. un sistema de evaluación de crédito no debe tener sesgos raciales o de género),
2. motivar sus predicciones de manera que un supervisor pueda hacer hipótesis de causalidad que luego verificará, descartando meras correlaciones fortuitas o dependientes de un tercer factor,
3. explicar sus salidas de manera que se pueda corroborar cómo de generalizables son. Por ejemplo, en el caso descrito en [8], un sistema de predicción de mortalidad por neumonía asignaba, erróneamente, menor riesgo a los pacientes que también padecían asma. Esto se debía a que estos pacientes habían recibido un tratamiento más agresivo por lo que, en el historial de datos analizados, sus porcentajes de recuperación solían mejorar respecto a otros pacientes; en consecuencia, el modelo automático asignaba un menor riesgo resultado de una mala generalización que posiblemente causaría el resultado contrario al esperado. Al utilizar el modelo derivado para asignar tratamientos, estos pacientes recibirían un tratamiento más leve, puesto que al haber obtenido históricamente mejores resultados, su riesgo estimado de mortalidad

sería menor,

4. ser informativo, es decir, ofrecer al supervisor información novedosa sobre las variables bajo estudio.

Estas características en ocasiones son incluso requeridas por ley, como en el caso del “derecho a la explicación” recogido en el nuevo Reglamento Europeo de Protección de Datos de la Unión Europea<sup>1</sup>, de manera que resultan no solo deseables en todo caso sino que también obligatorias en muchos otros.

Los algoritmos de aprendizaje automático ofrecen interpretabilidad generalmente de dos maneras distintas: (1) mediante la transparencia del modelo y/o del algoritmo, que permite al supervisor seguir la “lógica” usada para hacer las predicciones, como ocurre por ejemplo con las reglas de producción, o (2) interpretabilidad *post-hoc*, consistente en justificar las salidas bien ofreciendo casos similares o visualizaciones u otros métodos que ayuden a identificar las características de la entrada que llevan a una predicción. Esta segunda opción es la más común pero, aunque ofrece una explicación de cada caso individual, no es informativa ya que no ofrece al supervisor información general del entorno modelado.

Un problema adicional es que, si bien, el estudio de los mercados se ve potenciado por la inmensa cantidad de datos que se generan y recogen —tanto en entornos online como, en menor medida, en tiendas físicas— y la valiosa información que estos datos encierran, a su vez, su inmenso volumen dificulta la extracción de esta información. Por tanto, se requiere la utilización de algoritmos escalables que puedan procesarlos.

En este trabajo proponemos un nuevo algoritmo de agrupamiento de datos diádicos que se puede utilizar para realizar segmentación de mercado. Este algoritmo busca obtener datos fácilmente interpretables e informativos para un supervisor humano, mejorando así su proceso de toma de decisiones. Además, su implementación en la plataforma escalable Apache Spark [9] permite procesar grandes cantidades de datos para obtener información decisiva en un tiempo práctico. En la Sección II detallamos los trabajos previos de otros autores en este campo; en la Sección III se definen los principales conceptos manejados por el sistema propuesto y en la Sección IV presentamos el nuevo algoritmo. En la Sección V mostramos y comparamos los resultados de aplicar nuestro algoritmo a un conjunto de datos de lectores de noticias. Por último, la Sección VI resume las conclusiones obtenidas y el trabajo futuro que proyectamos realizar.

## II. TRABAJO RELACIONADO

Las técnicas de segmentación de mercado se pueden dividir atendiendo al origen de los datos que utilizan [10]:

1. *A priori*. Utilizan información de los compradores o de los productos que está disponible antes de su interacción en el mercado. Adolecen de no prestar atención al comportamiento de los actores en el mercado y ofrecer, por tanto, información limitada.

2. *Post-hoc*. Se basan en el estudio de los datos que se generan durante la actividad en el mercado. Es un enfoque más explorado para el que se han utilizado algoritmos de agrupamiento [11], árboles de clasificación y regresión [12], mapas autoorganizativos [13], algoritmos de reducción de la dimensionalidad [14] o algoritmos de co-agrupamiento [15].

Desde el punto de vista de la interpretabilidad, los algoritmos mencionados muestran características dispares. Mientras los resultados de algoritmos evolutivos y de co-agrupamiento no son apropiados si la interpretabilidad es un objetivo, los mapas autoorganizativos, y los algoritmos de reducción de la dimensionalidad y de agrupamiento ofrecen explicaciones *post-hoc* al supervisor. No obstante su capacidad de relacionar de manera sencilla las variables de entrada que describen a cada grupo es limitada, lo que reduce su utilidad para motivar sus predicciones y explicar sus salidas. Los árboles de clasificación y regresión, por otra parte, sí relacionan de manera clara las variables de entrada con las predicciones efectuadas y han sido utilizados con este fin sobre datos no diádicos [16], aunque su tamaño debe ser controlado para ofrecer explicaciones verificables por un supervisor.

## III. DEFINICIONES

Los datos diádicos  $X$  describen una interacción entre dos entidades  $\mathcal{U}$  e  $\mathcal{I}$ . Cada dato  $x \in \mathcal{X}$  tiene la forma  $(u, i, v)$  donde  $u \in \mathcal{U}$  y  $i \in \mathcal{I}$  son los elementos de cada entidad que se relacionan y  $v$  es un valor que informa respecto a esa interacción. Para cualesquiera  $u, i$  existirá un dato  $x$  que describirá su relación (ya sea observado o predicho), por lo cual se puede representar  $\mathcal{X}$  como una función  $f : (\mathcal{U}, \mathcal{I}) \rightarrow \{-1, +1\}$  que se denomina función de utilidad. Nótese que aunque  $v$  puede tomar cualquier valor, para este trabajo hacemos la simplificación de transformarlo a -1 o 1. Obtener una predicción del valor de esta función de utilidad es un problema muy habitual que se intenta resolver sobre estos datos y que ha sido repetidamente resuelto en la literatura mediante métodos como la factorización matricial [2]. Por otra parte, definiremos una agrupación  $Cl(\mathcal{U})$  sobre un  $\mathcal{U}$  como un conjunto de  $m$  grupos disjuntos que abarcan todos los elementos de  $\mathcal{U}$ . En fórmula:

$$Cl(\mathcal{U}) = \{Clu_1, \dots, Clu_m\}. \quad (1)$$

Se puede utilizar la homogeneidad de la función de utilidad dentro de cada grupo  $Clu_k$  para establecer la idoneidad de la agrupación [17]. Definiremos con este objetivo la proporción  $p$  de elementos positivos en un grupo se como

$$p_{kj} = Pr(+1|Clu_k, i_j) = \frac{|\{u \in Clu_k : f(u, i_j) = +1\}|}{|Clu_k|} \quad (2)$$

donde  $i_j$  representa el elemento  $j$ -ésimo de  $\mathcal{I}$ .

Diremos que un grupo  $Clu_k$  es *coherente* cuando haya gran consenso entre sus valores de  $f$ , es decir, que  $p$  se acerque a 0 o a 1. Podemos medir esta coherencia, como anunciamos, utilizando la entropía de  $p$ .

$$H(p) = -p \log_2(p) - (1 - p) \log_2(1 - p). \quad (3)$$

<sup>1</sup>[https://ec.europa.eu/info/law/law-topic/data-protection\\_en](https://ec.europa.eu/info/law/law-topic/data-protection_en)



$H(p_{kj})$  nos permite medir la coherencia de un único grupo  $Clu_k$  respecto al elemento  $i_j$ . Para extender esta medida a todo el agrupamiento  $Cl(\mathcal{U})$  debemos tener en cuenta todos sus grupos y todos los elementos de  $\mathcal{I}$ . Para conseguir esto, utilizaremos la media ponderada. Formalmente, definimos la *entropía ponderada (EP)* del agrupamiento  $Cl(\mathcal{U})$  como

$$EP(Cl(\mathcal{U})) = \sum_{k,j} \frac{|Clu_k|}{|\mathcal{U}||\mathcal{I}|} H(p_{kj}). \quad (4)$$

Con las características de interpretabilidad descritas en la Sección I en mente, en este trabajo nos enfocaremos en la capacidad de los algoritmos para motivar sus predicciones de manera sencilla utilizando las variables de entrada, con el objetivo de que un supervisor pueda formular y verificar hipótesis, así como también de resultar informativo respecto a la situación general del mercado en un instante dado. Debemos, por tanto, incluir en nuestra medida de idoneidad la complejidad de la explicación que requiere cada grupo, que mediremos con el número de variables que lo describen. Definimos, en consecuencia, la *calidad* de un agrupamiento como

$$calidad(Cl(\mathcal{U})) = -EP(Cl(\mathcal{U})) - \lambda \sum_{Clu_k \in Cl(\mathcal{U})} NV(Cl u_k). \quad (5)$$

donde  $NV$  se refiere al número de variables necesarias para describir  $Clu_k$  y  $\lambda$  es un hiperparámetro que permite al supervisor balancear la entropía del agrupamiento con su explicabilidad. Se puede comprobar que existe un balance entre la complejidad de la explicación y la precisión del agrupamiento obtenido, lo cual es esperable intuitivamente: para obtener grupos uniformes generalmente será preciso formar gran número de ellos, lo que obligará a describirlos con más variables; ambas cosas reducen la explicabilidad del modelo. Por el contrario, para obtener un modelo más explicable será necesario obtener un menor número de grupos descritos con menos variables, que consecuentemente tendrán que ser menos uniformes. El hiperparámetro  $\lambda$  permite al supervisor decidir cómo manejar esta disyuntiva.

Cabe destacar que, aunque la *calidad* así descrita es un número negativo, esto no es relevante. El objetivo del algoritmo será maximizar su valor, acercándolo a 0. Esta medida de *calidad* se puede aplicar a agrupamientos construidos con cualquier algoritmo sobre una entidad  $\mathcal{U}$  de un conjunto de datos diádicos.

#### IV. ALGORITMO PROPUESTO

En este trabajo proponemos un algoritmo de agrupamiento sobre datos diádicos (*post-hoc*) que obtenga grupos lo más homogéneos posibles y que, al mismo tiempo, se expliquen con el mínimo número posible de variables que describen a las entidades de la díada (*a priori*). De esta manera, en el escenario de la segmentación de mercado, el supervisor puede obtener información sobre cómo se dividen sus usuarios/productos y la relación entre estos grupos para así tomar decisiones informadas en consecuencia. Para ello se construirá

un árbol de decisión que describirá una agrupación  $Cl(\mathcal{U})$  en la que cada hoja del nodo representa un grupo descrito por las variables que conducen por el árbol hasta esa hoja.

El proceso global consiste en, a partir de la función de utilidad que relaciona a ambas entidades de la díada, realizar una exploración de los posibles árboles de decisión formados sobre las variables de entrada buscando maximizar la *calidad* de la agrupación resultante definida según la Ecuación 5.

Para poder explorar de manera eficiente el espacio de soluciones es necesario realizar ciertas simplificaciones. En primer lugar, para simplificar el cómputo de *calidad* de una agrupación y dado que el número de elementos de  $\mathcal{I}$  puede hacer impracticable su cálculo, en lugar de realizar el cómputo de entropía respecto a cada elemento de  $\mathcal{I}$ , consideraremos una muestra aleatoria representativa de los elementos de  $\mathcal{I}$ . Una manera de hacer esto es haciendo un agrupamiento previo de  $\mathcal{I}$  por procedimientos convencionales y tomando los centroides  $ci_j$  como representantes. Una vez calculados estos centroides, la proporción  $p$  descrita en la Ecuación 2 se aproximará como

$$p_{kj} = Pr(+1|Clu_k, ci_j) = \frac{|\{u \in Clu_k : f(u, ci_j) = +1\}|}{|Clu_k|} \quad (6)$$

y la Ecuación 4 deberá modificarse para tener en cuenta el tamaño del grupo  $Clu_k$  representado por  $ci_j$

$$EP(Cl(\mathcal{U})) = \sum_{k,j} \frac{|Clu_k||Clu_j|}{|\mathcal{U}||\mathcal{I}|} H(p_{kj}). \quad (7)$$

Por otra parte, dado que el problema de explorar todos los posibles árboles de decisión anteriormente descritos es generalmente inabarcable, se hace necesario establecer una estrategia de búsqueda. En primer lugar, para evitar que el árbol de decisión pueda bifurcarse en cualquier posible valor de cada variable de entrada, debe reducirse el número de estos puntos de bifurcación. Se establecerá, por tanto, un máximo de puntos de bifurcación por variable y estos se determinarán mediante discretización en el caso de las variables continuas.

A continuación se construirá el árbol de decisión realizando una búsqueda voraz. Para ello en cada nodo se tomará el candidato más prometedor, que se determinará utilizando una heurística. Por tanto, siendo  $v_i$  el  $i$ -ésimo punto de corte de la variable  $V$ , calcularemos la heurística del agrupamiento  $L = \{u \in \mathcal{U} : V(u) < v_i\}$ ,  $R = \{u \in \mathcal{U} : V(u) > v_i\}$  asociado a  $v_i$  con la siguiente fórmula, derivada de manera empírica:

$$\eta(L, R) = -EP(L) - EP(R) - (|L| - |R|)^2 \quad (8)$$

Realizando una búsqueda voraz en la que para cada nodo se tome el punto de bifurcación candidato con mejor heurística y repitiendo el proceso recursivamente para los grupos  $L$  y  $R$  obtenidos hasta alcanzar un nivel  $L_{MAX}$  preestablecido por el usuario, se construirá un único árbol de decisión de  $L_{MAX}$  niveles. Para expandir la cantidad de espacio de búsqueda explorado y mejorar así las posibilidades de obtener una buena solución, el algoritmo propuesto explora en cada paso no solo el candidato con mejor valor de la heurística, sino los  $N$  mejores, dando lugar a  $N$  árboles posibles. Cada uno de

esos árboles, a su vez, darán lugar a otros  $2 * N$  árboles al explorar el nivel siguiente, con lo cual el número de árboles explorados aumenta exponencialmente con el  $L_{MAX}$ . Deberá, en consecuencia, elegirse un valor bajo tanto para  $N$  como para  $L_{MAX}$ . El árbol de decisión obtenido será un árbol binario de  $L_{MAX}$  niveles y, por tanto, delimitará  $2^{L_{MAX}}$  grupos.

Este proceso aparece descrito en el Algoritmo 1.

**Datos:**  $U, f, L_{MAX}, N$

**Resultado:** Árbol de decisión que determina el agrupamiento.

**funcion**

```

CONSTRUYEARBOL( $U, nivel, puntosC, f, L_{MAX}, N$ )
  si  $nivel > NIVEL\_MAX$  entonces
    | devolver  $\emptyset$ 
  fin
  candidatos  $\leftarrow$  lista ordenada con capacidad  $N$ ;
  para ( $variable, valor$ )  $\in$   $puntosC$  hacer
1   |  $izq \leftarrow \{u \in U : u[variable] < valor\}$ ;
   |  $der \leftarrow \{u \in U : u[variable] > valor\}$ ;
   | si HEURISTICA( $izq, der$ )  $>$   $candidatos.minimo$ 
   |   entonces
2   |   |  $candidatos.añadir((variable, valor))$ ;
   |   fin
  fin
  mejor  $\leftarrow \emptyset$ ;
  para ( $variable, valor$ )  $\in$   $candidatos$  hacer
3   |  $izq \leftarrow \{u \in U : u[variable] < valor\}$ ;
4   |  $der \leftarrow \{u \in U : u[variable] > valor\}$ ;
5   |  $arbolIzq \leftarrow$  CONSTRUYEARBOL( $izq, nivel + 1, puntosCorte$ );
6   |  $arbolDer \leftarrow$  CONSTRUYEARBOL( $der, nivel + 1, puntosCorte$ );
7   |  $nuevo \leftarrow (variable, valor, arbolIzq, arbolDer)$ 
   |   si EP( $nuevo, f$ )  $>$  EP( $mejor, f$ ) entonces
8   |   |  $mejor = nuevo$ ;
   |   fin
  fin
  devolver  $mejor$ ;
fin

```

$puntosC \leftarrow$  lista de puntos de corte en todas las variables;

**devolver**

CONSTRUYEARBOL( $U, 0, puntosC, f, L_{MAX}, N$ );

**Algoritmo 1:** Algoritmo de construcción del agrupamiento.

Por último, es posible que tras completar la búsqueda un subconjunto de este árbol alcance mayor calidad que el árbol completo. Por tanto, se intentará mejorar la calidad de la agrupación eliminando grupos mediante un proceso de poda. Para ello se recorrerán los nodos desde  $L_{MAX} - 1$  hasta la raíz y se eliminarán aquellas bifurcaciones cuyo efecto en la calidad general no supere un *umbral* indicado por el usuario, tal como aparece detallado en el Algoritmo 2.

El algoritmo descrito consta de cálculos que se pueden

**Datos:**  $\text{árbol}, \text{umbral}, \lambda$

**Resultado:** Árbol podado.

**funcion** PODA( $\text{árbol}, \text{umbral}, \lambda, nivel$ )

```

1   | si ESHOJA( $\text{árbol}$ ) entonces
2   |   | devolver  $\text{árbol}$ ;
   |   fin
3   |  $izq \leftarrow$  PODA( $\text{árbol.ramaIzq}, \text{umbral}, nivel + 1$ );
4   |  $der \leftarrow$  PODA( $\text{árbol.ramaDer}, \text{umbral}, nivel + 1$ );
5   |  $entropíaDividido \leftarrow$ 
   |    $\frac{izq.entropía * |izq| + der.entropía * |der|}{|\text{árbol}|}$ ;
6   |  $\Delta E = entropíaDividido - \text{árbol.entropía}$ ;
7   |  $\Delta NV =$ 
   |    $izq.numVars + der.numVars - \text{árbol.numVars}$ ;
   |   si  $-\Delta E - \lambda \Delta NV < \text{umbral}$  entonces
8   |   |  $\text{árbol.ramaIzq} \leftarrow \emptyset$ ;
9   |   |  $\text{árbol.ramaDer} \leftarrow \emptyset$ ;
   |   devolver  $\text{árbol}$ ;
  fin
  devolver PODA( $\text{árbol}, \text{umbral}, \lambda, 0$ );

```

**Algoritmo 2:** Algoritmo de podado del árbol.

realizar en paralelo dado que son independientes. Para aprovechar esta característica se ha implementado en Apache Spark. Valiéndose de la computación distribuida que facilita Spark se aumenta la escalabilidad del algoritmo y se posibilita así el análisis de grandes conjuntos de datos en tiempos razonables.

## V. EXPERIMENTACIÓN

Para comprobar la validez de este algoritmo hemos realizado dos experimentos. En primer lugar hemos calculado un agrupamiento con una entropía ponderada comparable a la obtenida en [17] para una agrupación de 100 grupos obtenidos mediante K-Means. El segundo experimento consiste en comprobar el efecto sobre el tiempo de ejecución de la adición de más nodos de cómputo para el cálculo distribuido, para establecer qué nivel de escalabilidad tiene la implementación en Apache Spark del algoritmo propuesto.

Para ello hemos utilizado un conjunto de datos de la empresa Outbrain, liberado en el contexto de una competición auspiciada por el popular sitio web Kaggle.com. Outbrain es la empresa líder en descubrimiento de contenidos, mediante la sugerencia a lectores de noticias en las que pueden estar interesados. El conjunto de datos<sup>2</sup> recoge las visitas de un grupo de usuarios a las páginas web de multitud de publicaciones periódicas durante 14 días. De cada visita se registra, además de metadatos como la fecha, la localización o el medio empleado para conectarse, el documento visitado, del cual se conocen ciertos aspectos del contenido, y el resultado de su interacción con los anuncios mostrados en la página que, a su vez, enlazan a otros documentos. Aunque la competición original buscaba predecir qué anuncios tendrían más éxito en una situación dada, el problema que hemos decidido abordar

<sup>2</sup>El conjunto de datos está disponible para descargar en el sitio <https://www.kaggle.com/c/outbrain-click-prediction>



Cuadro I  
DESCRIPCIÓN DEL CONJUNTO DE DATOS

Conjunto	Atributos	Muestras
DIA1	647	1,289,506

es la agrupación de los pares usuario-documento en función de su comportamiento. Para ello hemos determinado las visitas correlativas de un usuario y hemos registrado la preferencia del usuario por un documento ofrecido frente a otros, obteniendo tuplas de preferencias sobre las que aprender la función de utilidad mediante factorización matricial [17]. Dado que los documentos visitados se refieren a temas de actualidad, las visitas registradas varían de temática con el tiempo y, por ello, tiene sentido agrupar los datos en subconjuntos más pequeños que abarquen menos tiempo. En particular, para este trabajo hemos utilizado los datos recogidos durante el primer día, descritos en el Cuadro I. De acuerdo a lo descrito en la Sección IV, hemos agrupado las noticias (conjunto  $\mathcal{L}$ ) en 100 grupos utilizando K-Means sobre los valores de la función de utilidad para cada noticia. El número de candidatos ( $N$ ) que hemos explorado para cada nodo es 5.

#### V-A. Resultados

Para realizar el primer experimento es necesario determinar un valor de  $\lambda$  y decidir qué nivel de profundidad adquirirá el árbol calculado. En este caso optamos por un árbol de 5 niveles. Al fijar este valor, la agrupación obtenida constará de 32 grupos descritos con 5 variables cada uno, con lo cual su valor  $NV$ , necesario para computar la calidad según la Ecuación 5 será de  $32 * 5 = 160$ . Tal como describimos en la Sección III, el valor  $\lambda$  debe balancear el valor de la entropía ponderada (que oscila entre 0 y 1) con el valor  $NV(Cl(U))$ , que en este caso oscilará entre 1 y 160. El valor de  $\lambda$  dependerá de la importancia que dé el supervisor a la interpretabilidad de la solución. En este experimento hemos tomado  $\lambda = 0,001$ .

Tras aplicar el algoritmo descrito al conjunto *DIA1* con los parámetros mencionados. La entropía ponderada de la agrupación es de 0.244 y, en consecuencia, su calidad es de -0.375. Tal como se indica en la Sección IV, este valor de calidad se puede mejorar con el proceso de poda descrito en el Algoritmo 2. Para ello es necesario establecer un umbral de mejora de la calidad que indique qué nodos deberán permanecer sin dividir. Habiendo calculado el árbol previamente, este proceso es lo suficientemente poco costoso como para que se pueda realizar la poda con cientos de umbrales distintos y representar en una gráfica los valores obtenidos, tal como se puede apreciar en la Figura 1. Tomando el valor de umbral (0.003) que obtiene mayor calidad, se obtuvo un árbol que describe 18 grupos, 2 de los cuales se describen usando 3 variables, 8 necesitan 4 variables y los 8 restantes se describen con 5 de las 647 variables. Su valor  $NV$  es, por tanto, 78, su entropía ponderada es de 0.2529 y su calidad es -0.3308. El árbol obtenido puede observarse en la Figura 2. Comparativamente, el agrupamiento obtenido en [17] ofrece una menor entropía ponderada (0.21), pero se compone de 100 grupos que precisan las 647 variables

Cuadro II  
TIEMPO DE CÓMPUTO DEL UN ÁRBOL DE 3 NIVELES. ESCALABILIDAD

# cores	Tiempo (H:M:S)		
	12	2x12	4x12
DIA1	3:19:46	2:35:33	1:33:45

para describir sus centroides, lo que se traduce en un valor de calidad muy bajo (-64,91). Si utilizásemos un árbol de clasificación para predecir a qué grupo pertenece cada muestra y de él extrajésemos nuevas descripciones para los grupos, aún en el caso óptimo estas nunca serían menos de 8 variables de media (en consecuencia  $NV = 800$ ), dado que se precisa un árbol binario de más de 8 niveles para discernir entre 100 elementos. Por tanto, la calidad de una agrupación compuesta de 100 grupos nunca será mayor de -1.01. Esto nos permite apreciar la utilidad del algoritmo propuesto para encontrar una agrupación bastante homogénea y con explicabilidad alta.

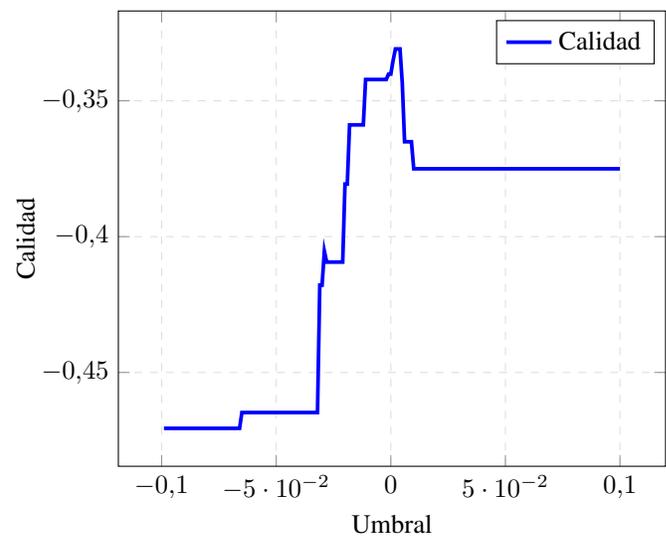


Figura 1. Calidad del agrupamiento vs umbral de bifurcación para el conjunto *DIA1* con  $\lambda = 0,001$ .

En segundo lugar, para comprobar la escalabilidad del algoritmo, realizamos el mismo cómputo varias veces variando el número de núcleos de computación involucrados en el cálculo para observar su efecto en el tiempo invertido. El cómputo que realizamos se corresponde a la búsqueda del árbol óptimo de tres niveles. Los tiempos de ejecución aparecen reflejados en el Cuadro II.

Como se puede apreciar, la independencia de los cálculos realizados, que facilita su cómputo en paralelo, y la facilidad de distribución del cálculo que proporciona Apache Spark provocan que la escalabilidad sea buena, correspondiéndose casi linealmente el incremento de nodos de computación con el descenso del tiempo de ejecución.

## VI. CONCLUSIONES

En este trabajo hemos reflexionado sobre las características que debe cumplir un algoritmo para ser considerado fácilmente

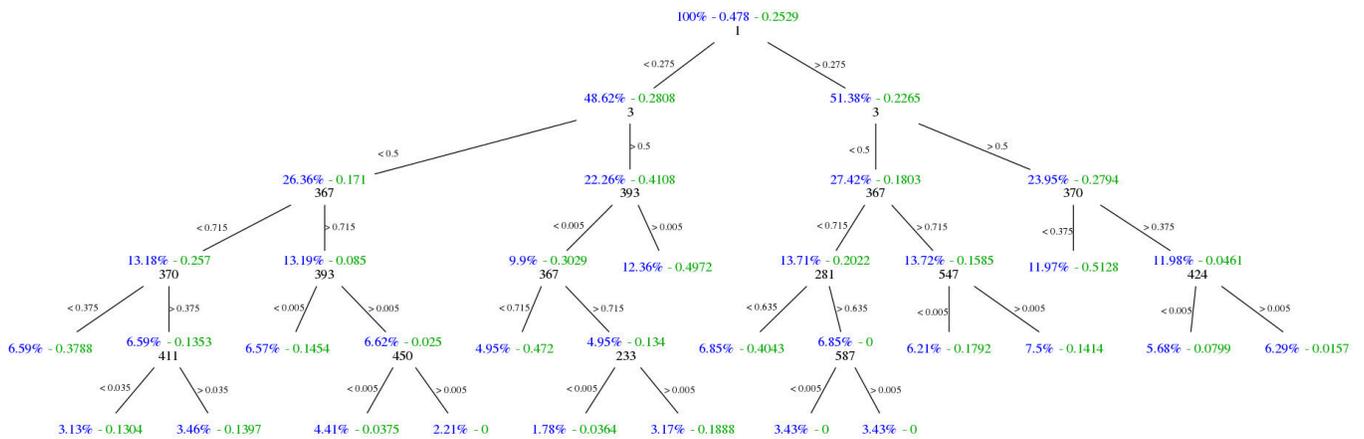


Figura 2. Árbol de decisión que determina el agrupamiento de los usuarios del conjunto de datos DIA1. En cada nodo se listan, respectivamente, la proporción de elementos que representa respecto al total (indicada en color azul), la entropía ponderada de ese nodo (verde) y la variable utilizada para la siguiente bifurcación (negro). Los valores utilizados para las bifurcaciones se indican al lado de las aristas. En la raíz se indica también en azul la entropía ponderada del conjunto entero.

interpretable y, adaptando una medida previamente utilizada en la literatura, hemos desarrollado un algoritmo de agrupamiento sobre datos diádicos que las cumple. El algoritmo propuesto permite, cuando es aplicado a datos referentes a interacciones en un mercado, realizar una segmentación de mercado a gran escala que ofrece a un supervisor información sobre qué está ocurriendo en ese medio en términos de las variables *a priori* que maneja. Asimismo, hemos realizado una implementación del citado algoritmo en la plataforma de computación distribuida Apache Spark que permite su aplicación a grandes volúmenes de datos y hemos realizado experimentos que verifican tanto la validez de este enfoque como la escalabilidad del mismo. Como trabajo futuro queremos adaptar este algoritmo para que pueda operar en situaciones en que el tiempo de cómputo es crucial. Para ello, queremos replantear la estrategia de búsqueda del árbol óptimo para que permita ser interrumpida en cualquier momento y ofrezca un resultado parcial relevante. Igualmente, creemos que la obtención de una heurística con mayor poder predictivo haría que la búsqueda fuese mucho más eficiente.

#### AGRADECIMIENTOS

Los autores desean agradecer a la Fundación Pública Galega Centro Tecnológico de Supercomputación de Galicia (CES-GA) el uso de sus recursos de computación.

#### REFERENCIAS

- [1] Thomas Hofmann, Jan Puzicha, and Michael I Jordan. Learning from dyadic data. In *Advances in neural information processing systems*, pages 466–472, 1999.
- [2] Yehuda Koren, Robert Bell, and Chris Volinsky. Matrix factorization techniques for recommender systems. *Computer*, 42(8), 2009.
- [3] Oscar Luaces, Jorge Díez, Amparo Alonso-Betanzos, Alicia Troncoso, and Antonio Bahamonde. A factorization approach to evaluate open-response assignments in moocs using preference learning on peer assessments. *Knowledge-Based Systems*, 85:322–328, 2015.
- [4] Oscar Luaces, Jorge Díez, Amparo Alonso-Betanzos, Alicia Troncoso, and Antonio Bahamonde. Content-based methods in peer assessment of open-response questions to grade students as authors and as graders. *Knowledge-Based Systems*, 117:79–87, 2017.

- [5] Philip Kotler and Keith Kohn Cox. *Marketing management and strategy*. Prentice Hall, 1980.
- [6] Philip Kotler. *Dirección de mercadotecnia: Análisis, planeación, implementación y control*. Magíster en Administración-Tiempo Parcial 29, ESAN, 2001.
- [7] Zachary C Lipton. The myths of model interpretability. *arXiv preprint arXiv:1606.03490*, 2016.
- [8] Rich Caruana, Yin Lou, Johannes Gehrke, Paul Koch, Marc Sturm, and Noemie Elhadad. Intelligible models for healthcare: Predicting pneumonia risk and hospital 30-day readmission. In *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 1721–1730. ACM, 2015.
- [9] Matei Zaharia, Reynold S Xin, Patrick Wendell, Tathagata Das, Michael Armbrust, Ankur Dave, Xiangrui Meng, Josh Rosen, Shivaram Venkataraman, Michael J Franklin, et al. Apache spark: a unified engine for big data processing. *Communications of the ACM*, 59(11):56–65, 2016.
- [10] Jiapeng Liu, Xiuwu Liao, Wei Huang, and Xianzhao Liao. Market segmentation: A multiple criteria approach combining preference analysis and segmentation decision. *Omega*, 2018.
- [11] Pavel Berkhin. A survey of clustering data mining techniques. In *Grouping multidimensional data*, pages 25–71. Springer, 2006.
- [12] Bo Fan and Pengzhu Zhang. Spatially enabled customer segmentation using a data classification method with uncertain predicates. *Decision Support Systems*, 47(4):343–353, 2009.
- [13] Melody Y Kiang, Michael Y Hu, and Dorothy M Fisher. An extended self-organizing map network for market segmentation—a telecommunication example. *Decision Support Systems*, 42(1):36–47, 2006.
- [14] Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-sne. *Journal of machine learning research*, 9(Nov):2579–2605, 2008.
- [15] Hanhuai Shan and Arindam Banerjee. Bayesian co-clustering. In *Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on*, pages 530–539. IEEE, 2008.
- [16] Jayanta Basak and Raghu Krishnapuram. Interpretable hierarchical clustering by constructing an unsupervised decision tree. *IEEE transactions on knowledge and data engineering*, 17(1):121–132, 2005.
- [17] Jorge Díez, Pablo Pérez, Oscar Luaces, and Antonio Bahamonde. Readers segmentation according to their preferences to click promoted links in digital publications. Technical report, Universidad de Oviedo, 2018.



# Bagging-RandomMiner - Un Algoritmo en MapReduce para Detección de Anomalías en Big Data

Luis Pereyra\*, Diego García-Gil†, Francisco Herrera†, Luis C. González-Gurrola\*, Jacinto Carrasco†, Miguel Angel Medina-Pérez‡ y Raúl Monroy‡

\*Facultad de Ingeniería, Universidad Autónoma de Chihuahua,  
Chihuahua, Chih. 31000, México  
Email: {a261804, lcgonzalez}@uach.mx

†Departamento de Ciencias de la Computación e Inteligencia Artificial,  
Universidad de Granada, Granada, España, 18071  
Email: {djgarcia,herrera,jacintocc}@decsai.ugr.es

‡Tecnológico de Monterrey, Campus Estado de México,  
Carretera al Lago de Guadalupe Km. 3.5, Atizapán de Zaragoza, Estado de México, 52926, México.  
Email: {migue, raulm}@itesm.mx

**Index Terms**—Detección de Anomalías, Big Data, MapReduce, Bagging-RandomMiner, Apache Spark, Detección de Anomalías

**Resumen**—La detección de anomalías es una tarea de interés en muchas aplicaciones del mundo real cuyo objetivo es identificar el comportamiento irregular de un proceso basado en el aprendizaje de cómo éste se comporta normalmente. En este trabajo, presentamos una versión MapReduce de una estrategia que ha demostrado ser exitosa para encontrar valores atípicos (anomalías) en conjuntos de datos de tamaño mediano. Esta estrategia, conocida como Bagging-RandomMiner, ahora ha sido extendida para aprovechar las bondades que Apache Spark ofrece y poder demostrar su utilidad en contextos de Big Data. Para evaluar su rendimiento, se ha utilizado el conjunto de datos PRIDE como Benchmark para identificar situaciones de estrés (anomalías) en un grupo de 23 sujetos. En este estudio comparamos Bagging-RandomMiner contra otra versión MapReduce del algoritmo que mejores resultados ha reportado sobre PRIDE, llamado OCKRA. Los experimentos indican que Bagging-RandomMiner supera claramente a OCKRA en al menos 6 % en el score AUC, más aún su tiempo de ejecución es al menos un orden de magnitud menor. Estos resultados soportan la idea de Bagging-RandomMiner como un algoritmo contendiente en tareas de Big Data. En este trabajo hacemos disponible el código de esta versión.

## I. INTRODUCCIÓN

Hoy en día el mundo avanza implacablemente hacia la era de Big Data. Todos los días se generan quintillones de datos. La *International Data Corporation* (IDC) predijo en 2014 que para 2020, el universo digital sería diez veces más grande que en 2013<sup>1</sup>. La tecnología actual se ha visto superada por esta cantidad de datos. Esto ha provocado que el concepto de Big Data aparezca como un nuevo paradigma para permitir

el almacenamiento y procesamiento de toda esta información. Dentro de los desafíos que presenta Big Data, hay uno de especial relevancia que ha encontrado un buen número de aplicaciones en el mundo real. La **detección de anomalías** se define como la tarea de averiguar cuándo un sistema o proceso está actuando erráticamente [1]. La importancia de esta tarea es tal que la existencia de un enfoque eficaz podría llevar a brindar soluciones a escenarios altamente sensibles, como seguridad en redes de computadoras, la detección de fraude bancario o incluso situaciones de vida o muerte [2], [3], [4].

Recientemente, se ha propuesto un algoritmo llamado Bagging-RandomMiner [5] para identificar anomalías o valores atípicos en conjuntos de datos de tamaño mediano. Motivados por la calidad de los resultados que ha registrado, incluso superando a conocidos competidores en tareas de Data Mining tales como AdaBoost.M1, Random Forrest y TreeBagger, entre otros, y su posible aplicación en escenarios de Big Data, presentamos en este artículo un diseño de MapReduce [6] de este algoritmo en el framework Apache Spark. Para evaluar este algoritmo utilizamos el conjunto de datos de Detección de Riesgos Personales (PRIDE) [7], que se creó para servir como benchmark para la detección de anomalías en el contexto de la detección de situaciones de estrés (o peligro) experimentadas por un grupo de 23 personas. Para contrastar los resultados obtenidos por Bagging-RandomMiner, también implementamos la versión MapReduce del algoritmo que mejores resultados ha reportado sobre PRIDE, conocido como OCKRA [8]. La comparación de ambas estrategias muestra que nuestro diseño supera los resultados del estado del arte en al menos  $\sim 6\%$  en el score promedio de Área Bajo la Curva (AUC), lo cual ha sido validado por el test Bayesian Signed-Rank test. Así mismo su tiempo de ejecución es al menos un

<sup>1</sup>IDC: The Digital Universe of Opportunities. 2018 [Online] Disponible: <http://www.emc.com/infographics/digital-universe-2014.htm>

orden de magnitud menor

Ponemos a disposición de la comunidad esta implementación en el repositorio respectivo de Spark<sup>2</sup>.

La organización de este trabajo se estructura de la siguiente manera: la Sección II presenta las definiciones básicas de la tarea de detección de anomalías, el conjunto de datos PRIDE y el modelo MapReduce. La Sección III describe el diseño del algoritmo distribuido propuesto. La Sección IV muestra los experimentos llevados a cabo sobre el conjunto de datos PRIDE. Finalmente, la Sección V brinda algunas conclusiones de este trabajo.

## II. ANTECEDENTES

### II-A. Detección de Anomalías

En la tarea de Detección de Anomalías (también conocida como detección de valores atípicos) [1], a diferencia de la clasificación binaria (o multiclase), el clasificador aprende a reconocer solo una categoría de objeto, la que pertenece a la clase mayoritaria. En general, se supone que la clase mayoritaria representa regularidad, es decir, objetos que se expresan a menudo en el dominio del problema. Suponiendo que el clasificador es competente en esta tarea, es fácil ver que éste discriminará automáticamente un objeto que no parece pertenecer a la clase mayoritaria, es decir, una anomalía.

Teniendo este contexto se puede ver que la Detección de Anomalías es relevante en una gran cantidad de escenarios, por ejemplo, para identificar ataques en la web [2], rastrear errores de software [3] y detección de fraude [4], entre otros. En este estudio nos enfocaremos en la tarea de detección de anomalías usando como Benchmark el conjunto de datos conocido como PRIDE.

### II-B. PRIDE y OCKRA

El conjunto de datos PRIDE fue diseñado originalmente por Barrera et al. [7] con el objetivo de ayudar a apoyar tareas de detección de anomalías en un escenario sensible de usuarios que experimentan situaciones estresantes. PRIDE fue creado con la ayuda de 23 usuarios que fueron supervisados durante una semana las 24 horas del día mientras realizaban sus actividades cotidianas. La recopilación de la información se logró a través de un sensor de la empresa Microsoft, llamado *Microsoft Band*. A partir de los datos generados por esta banda, se extrajeron 26 características. La Tabla I presenta las características consideradas en PRIDE para cada usuario. Para recolectar datos asociados a situaciones estresantes (condiciones de anomalía), los 23 usuarios fueron sometidos a diferentes escenarios de estrés que simulaban condiciones peligrosas que podrían enfrentarse en la vida real, por ejemplo, subiendo y bajando escaleras de un edificio, corriendo 16 metros a alta velocidad o una sesión de boxeo para simular una pelea, entre otras actividades [7]. En promedio hay 323,161 muestras por usuario y un total de 7,432,715 muestras para los 23 usuarios.

OCKRA a su vez, es el método que mejores resultados reporta usando la base de datos PRIDE, incluso superando a

<sup>2</sup><https://spark-packages.org/package/wuicho-pereyra/Bagging-RandomMiner>

Tabla I  
ESTRUCTURA DEL CONJUNTO DE DATOS PRIDE

Característica		Número	
Acelerómetro Giroscópico	Eje X	$\bar{x}$	1
		s	2
	Eje Y	$\bar{x}$	3
		s	4
	Eje Z	$\bar{x}$	5
		s	6
Velocidad Angular	Eje X	$\bar{x}$	7
		s	8
	Eje Y	$\bar{x}$	9
		s	10
	Eje Z	$\bar{x}$	11
		s	12
Acelerómetro	Eje X	$\bar{x}$	13
		s	14
	Eje Y	$\bar{x}$	15
		s	16
	Eje Z	$\bar{x}$	17
		s	18
Ritmo Cardíaco		19	
Temperatura de la piel		20	
Pasos		21	
Velocidad		22	
UV		23	
$\Delta$ Podómetro		24	
$\Delta$ Distancia		25	
$\Delta$ Calorías		26	

una Máquina de Vectores de Soporte para una sola clase (OC-SVM) [9]. El algoritmo *K-means One-Class with Randomly-projected features Algorithm* (OCKRA) [8] es un ensamble de 100 clasificadores de una sola clase, basado en múltiples proyecciones del conjunto de datos respecto a subconjuntos de datos aleatorios de características. OCKRA aplica k-means++ [10] a cada subconjunto de características para obtener una colección de centroides que representan la distribución de los datos. Para clasificar una nueva observación, cada clasificador determina una medida de similitud (0 – 1). Finalmente, se promedian las similitudes de cada clasificador y se obtiene la probabilidad de pertenencia a la clase mayoritaria.

### II-C. Modelo MapReduce

MapReduce es un framework introducido por Google en 2003 [6]. Este modelo se compone de dos procedimientos para procesar datos de forma paralela: *Map* y *Reduce*. La operación de *Map* realiza una transformación a los datos de entrada, mientras que el método *Reduce* consiste en una operación de agregación. El flujo de trabajo de un programa MapReduce se compone de cuatro pasos: primero, el nodo maestro divide los datos de entrada y los distribuye en todos los nodos. En segundo lugar, la operación *Map* aplica una transformación a los datos presentes localmente. A continuación, los resultados se redistribuyen en el clúster en función de los pares clave-valor generados en la operación *Map*. Después de que este proceso haya finalizado, todos los pares que pertenecen a una misma clave están en el mismo nodo. Finalmente, los pares clave-valor se procesan en paralelo.

Apache Spark<sup>3</sup> es un framework de código abierto basado en

<sup>3</sup>Apache Spark Project 2018 [Online] Disponible: <https://spark.apache.org/>



el modelo MapReduce construido para favorecer la eficiencia, la facilidad de uso y el cálculo en memoria interna [11], [12]. La característica central de Spark son los *Resilient Distributed Datasets* (RDDs) [13]. Los RDDs se pueden describir como una colección distribuida e inmutable de particiones de los datos, distribuidos por el clúster. Los RDDs implementan dos tipos de operaciones: (i) transformaciones, que no se evalúan cuando se definen y devuelven un nuevo RDD después de aplicar una función; y (ii) acciones, que devuelven un valor y desencadenan todas las transformaciones previas del RDD. Todas las transformaciones se aplican en paralelo a cada partición.

### III. UNA VERSIÓN MAPREDUCE DE BAGGING-RANDOMMINER

Para una descripción de la versión local del algoritmo Bagging-RandomMiner se sugiere al lector consultar el trabajo [5]. Bajo el modelo de MapReduce se usaron las siguientes funciones de Spark: (i) **mapPartitions** (aplica una función a cada partición de un RDD y devuelve un nuevo RDD), (ii) **zipWithIndex** (agrega a un RDD sus índices de elementos) y, (iii) **join** (devuelve un RDD que contiene todos los pares de elementos con claves coincidentes en éste y otro RDD). Bagging-RandomMiner está compuesto por dos fases: aprendizaje y clasificación. En la fase de aprendizaje, se selecciona de manera aleatoria un porcentaje  $RS$  de los datos. A partir de esta muestra, se realiza otro sub muestreo para seleccionar aquellos objetos que representarán la distribución completa de los objetos originales, los cuales son llamados **Objetos Más Representativos de la población (MRO)**. A partir de aquí, se calcula un umbral de decisión ( $\delta$ ) promediando la matriz de distancia de los MRO con la ayuda de la función *mapPartitions*. Esto se hace iterativamente para un número  $T$  de clasificadores. En la fase de clasificación, debido a que los RDD se distribuyen aleatoriamente de forma natural, la función *zipWithIndex* se aplica para agregar un índice a cada instancia. Luego, cada instancia de test se compara con los MRO, eligiendo solo el que tenga la distancia más cercana a la instancia de test. Finalmente, la similitud se calcula con la distancia más cercana y el umbral ( $\delta$ ), esto corresponde a la probabilidad del comportamiento genuino. Este proceso se repite hasta que se completen los  $T$  clasificadores, y, mediante la función *join*, se almacena el voto de cada clasificador, lo que nos permite promediar un resultado final. La Figura 1 muestra un diagrama del funcionamiento de ambas fases.

#### III-A. Fase de Aprendizaje

El Algoritmo 1 es la clase principal que orquesta la operación de Bagging-RandomMiner. Para iniciar el procedimiento, es necesario proporcionar el conjunto de entrenamiento (*dataTrain*) y el conjunto de prueba (*dataTest*) en la estructura RDD de tipo *LabeledPoint*, el número de clasificadores ( $T$ ), el porcentaje de objetos seleccionados para cada clasificador ( $RS$ ), el porcentaje de objetos más representativos ( $MRO_{percent}$ ) y el tipo de distancia que se aplicará (*disType*; 1  $\rightarrow$  euclidea, 2  $\rightarrow$  manhattan y 3  $\rightarrow$

chebyshev). En el paso 5, un clasificador se entrena aplicando el Algoritmo 2, pasando los parámetros de *dataTrain*,  $RS$  y  $MRO_{percent}$  como argumentos. En el paso 7, se obtiene una predicción del conjunto de test aplicando el Algoritmo 3, pasando como parámetros el conjunto de prueba y el modelo entrenado. Luego, cada vez que se hace una predicción del conjunto de test, la función de *union* se usa para almacenar las predicciones de cada clasificador (paso 8). Finalmente, en el paso 10, se promedian los resultados del clasificador para obtener la probabilidad de pertenencia al comportamiento genuino de cada instancia de test, y se devuelve en una variable con estructura RDD [índice, probabilidad, clase real].

El Algoritmo 2 es la parte principal de la fase de aprendizaje. Aquí es donde se determinan los  $MRO$  y el umbral de decisión para la clasificación de un nuevo objeto. Los parámetros necesarios para comenzar con esta etapa son: *dataTrain*,  $RS$ ,  $MRO_{percent}$  y *disType*. Primero, debemos determinar los MRO del conjunto. Para lograr esto, en el paso 3 elegimos aleatoriamente el porcentaje de  $RS$  de los datos que serán usados por el clasificador para representar la distribución de los datos originales. Luego, en el paso 4, el porcentaje de  $MRO$  indicado se selecciona aleatoriamente, siendo estos objetos los prototipos que representan el clasificador. Ahora, para determinar el umbral de decisión ( $\delta$ ) es necesario calcular la matriz de distancias. Con la ayuda de la función *mapPartitions*, la matriz de distancias se calcula para cada nodo, es decir, en paralelo, cada nodo es responsable de calcular el promedio de la matriz de distancias con los  $MRO$  correspondientes. Al final, cada uno de los promedios se recopila y se calcula el promedio de estos resultados, que es el umbral de decisión  $\delta$  (pasos 5-15). Finalmente, se crea un modelo y se devuelven los  $MRO$ , el umbral calculado  $\delta$  y el tipo de distancia utilizada (paso 16).

#### III-B. Fase de predicción

El Algoritmo 3 es responsable de la clasificación de los nuevos objetos. Para lograr esto, necesitamos el *DataTest* y el modelo entrenado por el Algoritmo 2. El proceso comienza aplicando la función *zipWithIndex* (paso 3) que asigna un índice a cada instancia para no perder el orden y poder aplicar la función de unión en el algoritmo 1. Después, con la ayuda de la función *mapPartitions*, la distancia de cada objeto de test se calcula con todas las  $MRO$  distribuidos en cada nodo. Al final, se elige la distancia más cercana ( $d_{min}$ ) al objeto de test (paso 10) y la medida de similitud se calcula con la  $d_{min}$  obtenida y el umbral de decisión  $\delta$  (paso 11). Cuando todos los nodos terminan sus respectivas ejecuciones, el Algoritmo 3 devuelve un RDD [índice, probabilidad] (paso 14).

## IV. RESULTADOS EXPERIMENTALES

Los experimentos se diseñaron utilizando *5-fold cross-validation* y dos versiones de Bagging-RandomMiner, variando el número de clasificadores en el ensamble: 10 y 50, respectivamente. Este último aspecto es interesante de evaluar ya que OCKRA también es un método de ensamble con un número fijo de clasificadores igual a 100. En cuanto a los

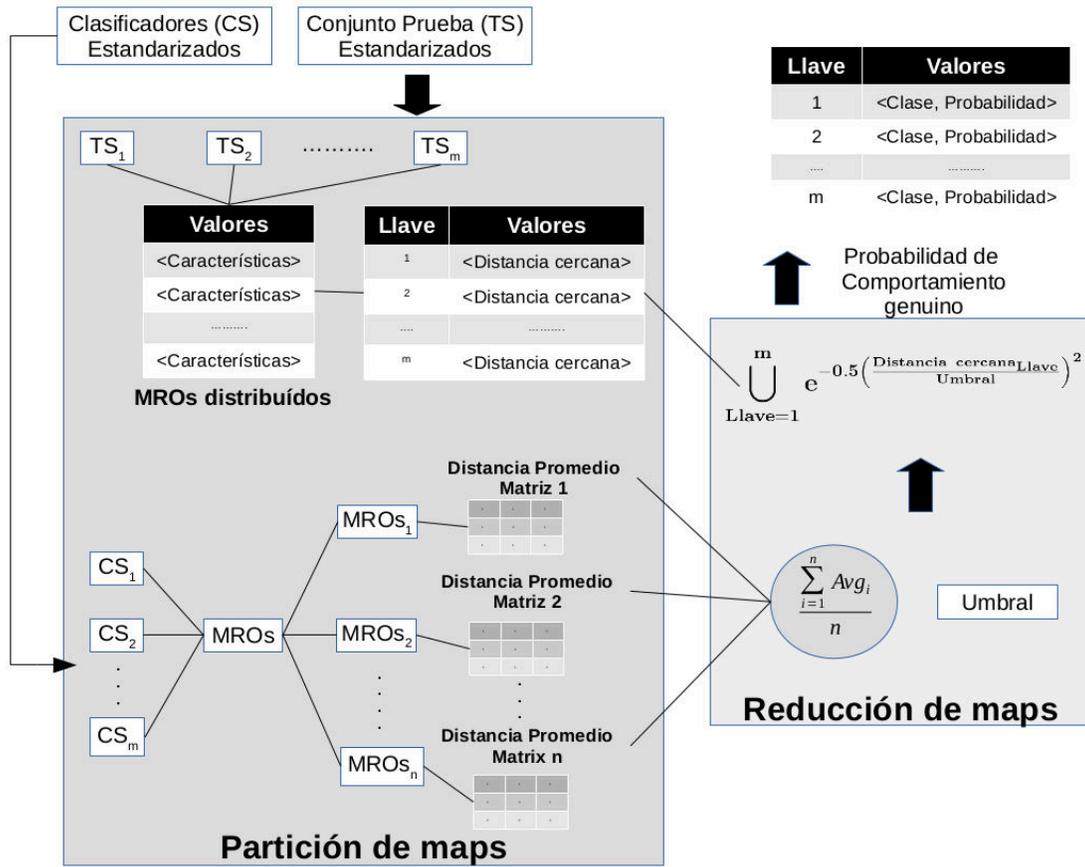


Figura 1. Diagrama de aprendizaje y predicción de Bagging-RandomMiner en MapReduce.

**Algoritmo 1** Main Bagging-RandomMiner

- 1: **Entrada:** *datos*: RDD de tipo *LabeledPoint* (características, clase), *prueba*: RDD de tipo *LabeledPoint* (características, clase) *T*: número de clasificadores, *RS*: porcentaje de muestreo, *MRO<sub>percent</sub>*: porcentaje de *MROs* y *distType*: tipo de distancia.
- 2: **Salida:** Probabilidad de pertenencia al comportamiento genuino.
- 3: **for**  $i = 0 \dots T$  **do** || Itera para crear un modelo de cada clasificador.
- 4:     || Se manda llamar el algoritmo 2.
- 5:     *Model*  $\leftarrow$  Aprendizaje(*dataTrain*, *RS*, *MRO<sub>percent</sub>*, *distType*)
- 6:     || Se manda llamar el algoritmo 3
- 7:     *pred\_tmp*  $\leftarrow$  Predicción(*dataTest*, *Model*)
- 8:     *predicciones.join(pred\_tmp)* || Con la función *join*, las predicciones se almacenan con la llave índice.
- 9: **end for**
- 10: **return** Promedio(*predicciones*) || Los resultados de cada modelo son promediados, esto corresponde a la probabilidad del comportamiento genuino

**Algoritmo 2** Aprendizaje

- 1: **Entrada:** *dataTrain*: RDD de tipo *LabeledPoint* (características, clase), *RS*: porcentaje de muestreo, *MRO<sub>percent</sub>*: porcentaje de *MROs* y *distType*: tipo de distancia.
- 2: **Salida:** El modelo entrenado, un objeto de clase *RandomMiner*
- 3: *dataTrain'*  $\leftarrow$  Clasificador(*dataTrain*, *RS*) || Un porcentaje de los datos es seleccionado aleatoriamente.
- 4: *MROs*  $\leftarrow$  Seleccionar(*MRO<sub>percent</sub>*, *dataTrain'*) || Un porcentaje de *MRO* es seleccionado aleatoriamente.
- 5: **mapPartition**  $l \in MROs$  || Computar la distancia de cada *MRO*.
- 6:     *Distance*  $\leftarrow$  0 || Se inicializa la distancia.
- 7:     **for**  $i = 0$  To *size*(*l*) **do** || Itera sobre cada *MRO* de la partición.
- 8:         **for**  $j = i + 1$  To *size*(*l*) **do** || Itera sobre cada *MRO* de la partición.
- 9:             || Se calcula la distancia entre cada par de *MRO*
- 10:             *Distance*  $\leftarrow$  *Distance* + CalcDist(*l*(*i*), *l*(*j*), *distType*)
- 11:         **end for**
- 12:     **end for**
- 13:     *umbral.append(Avg(Distance))* || El promedio de cada partición.
- 14: **end mapPartition**
- 15:  $\delta \leftarrow$  Avg(*umbral*) || Promedio global de las particiones.
- 16: **return** (*MROs*,  $\delta$ , *distType*) || Se retorna un modelo con los *MRO*, el umbral  $\delta$  y el tipo de distancia.

parámetros de *RandomMiner*, se usaron la distancia chebyshev y los valores del 1% para muestreo de los datos y 1% de objetos *MRO*.

La métrica para evaluar los modelos es el área bajo la curva (*AUC*) de la tasa de detección positiva (comportamiento

genuino) (*TP*) versus la tasa de detección de falso positivo (comportamiento anormal) (*FP*). Este indicador de acuerdo con [14] es una excelente medida para evaluar clasificadores

**Algoritmo 3** Predicción

---

```

1: Entrada: dataTest: RDD de tipo LabeledPoint (características,
   clase), Model: modelo entrenado (MRO,  $\delta$ , disType).
2: Salida: Probabilidad de pertenencia al comportamiento genuino.
3: testIndex  $\leftarrow$  zipWithIndex(dataTest) || Un índice es añadido
   a cada instancia.
4: mapPartition  $l \in testIndex$  || Se evalúa por partición el
   conjunto de prueba (maps)
5:   for  $i = 0$  To size(l) do || Itera sobre cada instancia de la
   partición.
6:     for  $j = 0$  To size(MROs) do || Itera sobre cada MRO
   de la partición.
7:       || Se calcula la distancia entre cada instancia de
   prueba y los MRO.
8:        $Distance(j) \leftarrow CalcDist(l(i), MRO(j), disType)$ 
9:     end for
10:     $dmin \leftarrow \min(Distance)$  || Para cada instancia de
   prueba, se determina la más cercana a los MRO.
11:     $similaridad \leftarrow e^{-0.5(\frac{dmin}{\delta})^2}$  || Se determina la simila-
   ridad de la distancia más cercana.
12:  end for
13: end mapPartition
14: return similaridad de tipo RDD || Probabilidad del comport-
   tamiento genuino.

```

---

de una clase. Finalmente, para tener mejor evidencia que la ofrecida por test frecuentistas [15], se aplicó la prueba estadística *Bayesian Signed Rank Test* [16] para comparar la métrica AUC de la mejor versión de Bagging-RandomMiner vs OCKRA.

La infraestructura de cómputo (clúster) utilizado para todos los experimentos en este trabajo está compuesto por 14 nodos gestionados por un nodo maestro. Todos los nodos tienen la misma configuración de *hardware* y *software*. En cuanto al *hardware*, cada nodo tiene 2 procesadores *IntelXeonE5 – 2620*, 6 núcleos (12 hilos) por procesador, 2 GHz y 64 GB de RAM. La red utilizada es *Infiniband* de 40Gb/s. El sistema operativo es Cent OS 6.5, con Apache Spark y MLib 2.2.0, 336 núcleos (24 núcleos / nodo), 728 GB de RAM (52 GB / nodo).

La Figura 2 muestra el porcentaje del score AUC para cada uno de los 23 sujetos que integran el dataset PRIDE obtenido por RandomMiner (2 configuraciones) y OCKRA. De acuerdo a esta figura se pueden obtener 2 conclusiones: (1) los resultados de RandomMiner mejoran la identificación de anomalías en prácticamente todos los usuarios, y (2) No hay una diferencia marcada entre usar 10 clasificadores o 50 para RandomMiner. Este último punto sugiere que el método es robusto.

Para analizar estadísticamente los resultados se aplicó el test no paramétrico *Bayesian Signed Rank* a un nivel de confianza del 95 %. Este test, a diferencia de los test frecuentistas (t-test), nos permite ser más concluyentes respecto a las diferencias de los algoritmos comparados [15]. En la Figura 3 se muestra a través de coordenadas baricéntricas la distribución de diferencias en el desempeño de los algoritmos en tres regiones: *left* (OCKRA es mejor que RandomMiner), *rope* (no hay

diferencia) y *right* (RandomMiner es mejor que OCKRA). Observando esta figura es evidente que la mayoría de los casos se inclina más a RandomMiner que a la región de no diferencia y definitivamente más que a soportar la probabilidad de que OCKRA sea el mejor algoritmo.

La Figura 4 muestra el tiempo de ejecución total para las dos versiones de RandomMiner, 10 y 50 clasificadores con 256 *maps* para cada ejecución y OCKRA. Ambas versiones de RandomMiner tienen un mejor tiempo de ejecución que OCKRA, ahora, si consideramos que usando 10 clasificadores en RandomMiner es suficiente para obtener resultados competitivos esta diferencia se vuelve sustancial.

Dado que la contribución de este artículo es un nuevo diseño escalado de Bagging-RandomMiner, es importante contextualizar el tiempo de ejecución con respecto a la versión original del mismo algoritmo, llamado Local, esto se puede observar en la Figura 5. La escalabilidad de Bagging-RandomMiner es notable, ya que el tiempo de ejecución del algoritmo por usuario pasó de 14.4 horas a 3.66 minutos en promedio.

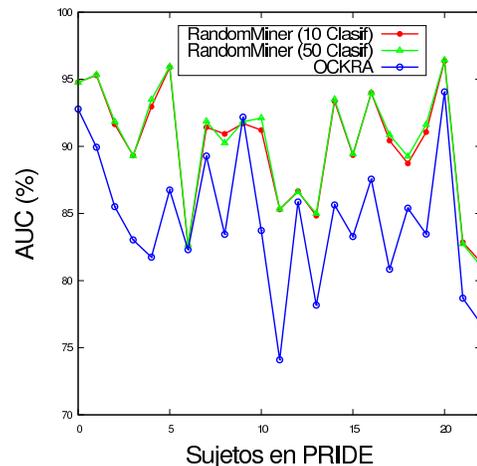


Figura 2. Porcentaje de Área bajo la curva (AUC) para RandomMiner (2 configuraciones) y OCKRA para cada uno de los 23 sujetos en PRIDE

## V. CONCLUSIONES

En este trabajo, se ha propuesto un diseño escalable y distribuido del algoritmo Bagging-RandomMiner desde la perspectiva MapReduce, basada en la filosofía de ensambles y aleatoriedad, que permite abordar problemas con alta dimensionalidad en el área de clasificación de una sola clase, para la detección de anomalías y conjuntos de datos altamente desequilibrados. Los resultados sugieren que Bagging-RandomMiner supera a OCKRA, la mejor estrategia para la detección de anomalías en el conjunto de datos PRIDE. Además, el método parece ser robusto con respecto al número de clasificadores que considera, ya que con un número muy pequeño de clasificadores (10) se logra un alto rendimiento y mejora sustancialmente el tiempo de ejecución.

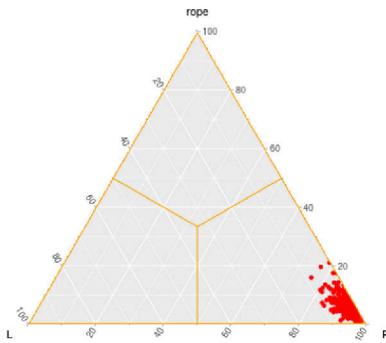


Figura 3. Resultados del Bayesian Signed Rank test sobre los resultados de OCKRA y Bagging-RandomMiner. La aglutinación de datos en la esquina inferior derecha (asociada a RandomMiner) sugiere fuertemente que éste es mejor algoritmo que OCKRA.

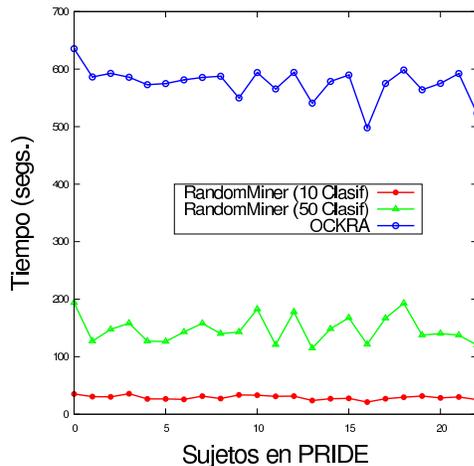


Figura 4. Tiempo de ejecución de los algoritmos RandomMiner (2 configuraciones) y OCKRA para cada uno de los 23 sujetos en PRIDE

**Agradecimientos:** Se agradece al Consejo Nacional de Ciencia y Tecnología de México (CONACYT) por la beca 620097 para estudios de posgrado otorgada al primer autor.

#### REFERENCIAS

- [1] B. Krawczyk and B. Cyganek, "Selecting locally specialised classifiers for one-class classification ensembles," *Pattern Anal. Appl.*, vol. 20, no. 2, pp. 427–439, May 2017. [Online]. Available: <https://doi.org/10.1007/s10044-015-0505-z>
- [2] C. Kruegel and G. Vigna, "Anomaly detection of web-based attacks," in *Proceedings of the 10th ACM Conference on Computer and Communications Security*, ser. CCS '03. New York, NY, USA: ACM, 2003, pp. 251–261. [Online]. Available: <http://doi.acm.org/10.1145/948109.948144>
- [3] S. Hangal and M. S. Lam, "Tracking down software bugs using automatic anomaly detection," in *Proceedings of the 24th International Conference on Software Engineering*, ser. ICSE '02. New York, NY, USA: ACM, 2002, pp. 291–301. [Online]. Available: <http://doi.acm.org/10.1145/581339.581377>
- [4] T. Fawcett and F. Provost, "Adaptive fraud detection," *Data Mining and Knowledge Discovery*, vol. 1, no. 3, pp. 291–316, Sep 1997. [Online]. Available: <https://doi.org/10.1023/A:1009700419189>
- [5] J. B. Camiña, M. A. Medina-Pérez, R. Monroy, O. Loyola-González, L. A. P. Villanueva, and L. C. González-Gurrola, "Bagging-randomminer: a one-class classifier for file access-based masquerade detection," *Machine Vision and Applications*, Jul 2018. [Online]. Available: <https://doi.org/10.1007/s00138-018-0957-4>

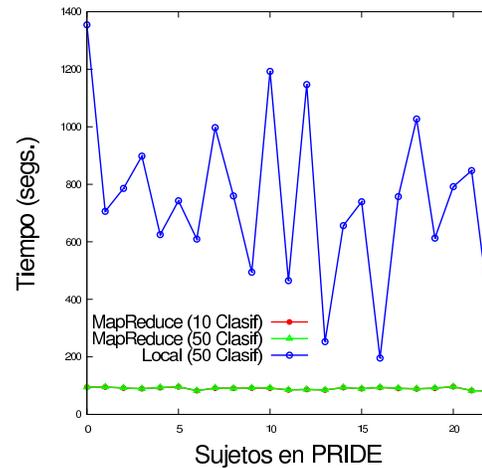


Figura 5. Tiempo de ejecución de los algoritmos RandomMiner en versión MapReduce y local.

- [6] J. Dean and S. Ghemawat, "Mapreduce: Simplified data processing on large clusters," in *Proceedings of the 6th Conference on Symposium on Operating Systems Design & Implementation - Volume 6*, ser. OSDI'04, 2004, pp. 10–10.
- [7] A. Y. Barrera-Animas, L. A. Trejo, S. García, M. A. Medina-Pérez, and R. Monroy, "Online Personal Risk Detection Based on Behavioural and Physiological Patterns," *Information Sciences*, August 2016.
- [8] J. Rodríguez, A. Y. Barrera-Animas, L. A. Trejo, M. A. Medina-Pérez, and R. Monroy, "Ensemble of one-class classifiers for personal risk detection based on wearable sensor data," *Sensors*, vol. 16, no. 10, 2016.
- [9] L. Trejo and A. Barrera-Animas, "Towards an efficient one-class classifier for mobile devices and wearable sensors on the context of personal risk detection," *Sensors*, vol. 18, no. 9, 2018.
- [10] D. Arthur and S. Vassilvitskii, "K-means++: The advantages of careful seeding," in *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*, ser. SODA '07. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 2007, pp. 1027–1035. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1283383.1283494>
- [11] D. García-Gil, S. Ramírez-Gallego, S. García, and F. Herrera, "A comparison on scalability for batch big data processing on Apache Spark and Apache Flink," *Big Data Analytics*, vol. 2, no. 1, p. 11, Mar 2017.
- [12] D. García-Gil, S. Ramírez-Gallego, S. García, and F. Herrera, "Principal components analysis random discretization ensemble for big data," *Knowledge-Based Systems*, vol. 150, pp. 166 – 174, 2018.
- [13] M. Zaharia, M. Chowdhury, T. Das, A. Dave, J. Ma, M. McCauley, M. J. Franklin, S. Shenker, and I. Stoica, "Resilient distributed datasets: A fault-tolerant abstraction for in-memory cluster computing," in *Proceedings of the 9th USENIX Conference on Networked Systems Design and Implementation*, ser. NSDI'12. Berkeley, CA, USA: USENIX Association, 2012, pp. 2–2. [Online]. Available: <http://dl.acm.org/citation.cfm?id=2228298.2228301>
- [14] T. Fawcett, "An introduction to roc analysis," *Pattern Recogn. Lett.*, vol. 27, no. 8, pp. 861–874, Jun. 2006. [Online]. Available: <http://dx.doi.org/10.1016/j.patrec.2005.10.010>
- [15] A. Benavoli, G. Corani, J. Demsar, and M. Zaffalon, "Time for a change: a tutorial for comparing multiple classifiers through bayesian analysis," *Journal of Machine Learning Research*, vol. 18, pp. 1–36, 2017.
- [16] J. Carrasco, S. García, M. del Mar Rueda, and F. Herrera, "rnpbst: An r package covering non-parametric and bayesian statistical tests," in *Hybrid Artificial Intelligent Systems*, F. J. Martínez de Pisón, R. Urraca, H. Quintián, and E. Corchado, Eds. Cham: Springer International Publishing, 2017, pp. 281–292.



# CGLAD: GLAD en problemas de Big Crowdsourced Data

Enrique G. Rodrigo

Departamento de Sistemas Informáticos  
Universidad de Castilla-La Mancha  
Albacete, España  
Enrique.GRodrigo@uclm.es

Juan A. Aledo

Departamento de Matemáticas  
Universidad de Castilla-La Mancha  
Albacete, España  
JuanAngel.Aledo@uclm.es

José A. Gámez

Departamento de Sistemas Informáticos  
Universidad de Castilla-La Mancha  
Albacete, España  
Jose.Gamez@uclm.es

**Resumen**—En este artículo proponemos una mejora del algoritmo GLAD con el fin de mejorar su funcionamiento en problemas con grandes conjuntos de datos, en términos de eficiencia y de precisión del modelo resultante. El algoritmo GLAD permite aprender a partir de datos procedentes de múltiples anotadores, teniendo en cuenta su capacidad y la dificultad de las instancias que se predicen. Sin embargo, debido al número de parámetros del modelo, este no escala bien a grandes cantidades de datos, sobre todo si se requiere que el tiempo de ejecución sea bajo. Nuestra propuesta, que llamamos CGLAD, resuelve en gran medida estos problemas mediante *clustering* a partir de vectores procedentes de factorización de matrices, lo que permite reducir el número de parámetros del modelo y, en general, facilitar el aprendizaje de modelos que siguen la estrategia de GLAD.

**Index Terms**—aprendizaje automático no estándar, crowdsourcing, múltiples anotadores, débilmente supervisado

## I. INTRODUCCIÓN

El algoritmo GLAD [5] permite abordar problemas de aprendizaje automático a partir de múltiples anotadores (por ejemplo, los que proceden de plataformas de *crowdsourcing*) [7]. Este problema se enmarca dentro del aprendizaje automático no estándar [2], el cual aborda el análisis de conjuntos de datos que difieren en ciertas características del aprendizaje de aprendizaje automático tradicional. Concretamente, en el aprendizaje a partir de múltiples anotadores no disponemos de la etiqueta verdadera de los ejemplos, si no que disponemos de varias anotaciones para cada ejemplo procedentes de anotadores de calidad desconocida, por lo que se obtiene un conjunto de datos como el de la Tabla I.

$Y_1$	$Y_2$	...	$Y_N$
0	0	...	1
1	1	...	-
0	-	...	0
1	0	...	1
1	-	...	1
...	...	...	...

Tabla I: Ejemplo de conjunto de anotaciones

Este trabajo ha sido parcialmente financiado por la Agencia Estatal de Investigación (AEI) y el Fondo Europeo de Desarrollo Regional (FEDER, UE) mediante los proyectos TIN2016-77902-C3-1-P y TIN2016-82013-REDT. Enrique G. Rodrigo también ha sido financiado por el MECD mediante la beca FPU15/02281.

Aparte de estas anotaciones es posible obtener más características de las instancias, existiendo algoritmos [4] que permiten hacer uso de estas características a medida que se aprende un modelo. Sin embargo, gran parte de los algoritmos en esta línea trabaja en resolver únicamente el problema de agregación de estas etiquetas [8]. El objetivo último es poder aprender un modelo a partir de estas anotaciones que permita predecir la clase verdadera para cada instancia, que entonces podrá utilizarse en un algoritmo de aprendizaje automático tradicional. El enfoque más sencillo y empleado es el de usar la clase más frecuente como entrada de un algoritmo de aprendizaje automático, método comúnmente conocido como *Majority Voting* cuando tenemos una variable de salida de tipo discreto (en el caso continuo usaríamos la media). Sin embargo, en la actualidad, existen algoritmos más efectivos a la hora de agregar opiniones puesto que permiten tener en cuenta información tal como la experiencia de los anotadores [1] o, incluso, la dificultad de cada ejemplo [5]. Esta información no solo es útil para estimar la verdadera etiqueta, si no que puede resultar interesante en numerosos problemas.

Este tipo de algoritmos es especialmente interesante cuando el tamaño del problema es mayor, ya que es en este caso cuando es más complejo obtener un gran número de anotaciones fiables a partir de expertos (o, en general, de personas en las que podamos confiar) en un determinado problema. Es, por tanto, recomendable, que los algoritmos utilizados en la agregación de etiquetas puedan ser escalables a una gran cantidad de datos, de forma que puedan aplicarse también en estos casos.

En este artículo exponemos algunos problemas relacionados con la escalabilidad del algoritmo GLAD, uno de los algoritmos principales en la agregación de anotaciones cuando uno está interesado no solo en evaluar la calidad de los anotadores sino también en la dificultad de los ejemplos. Por otro lado, proponemos una mejora de este algoritmo, CGLAD, que permite abordar problemas de mayor envergadura y facilita en gran medida el uso de este en todos los contextos, añadiendo una mayor estabilidad frente a ligeros cambios en la configuración del algoritmo. Por último, ofrecemos una serie de comparativas con ambos métodos y exponemos nuestras conclusiones al respecto.

## II. EL ALGORITMO GLAD

El algoritmo GLAD [5] permite resolver problemas de aprendizaje con clase binaria usando múltiples anotaciones. A diferencia de otros algoritmos [1], [3], [4], permite estimar tanto la precisión de cada anotador como la dificultad de cada ejemplo. A continuación describiremos en qué consiste este algoritmo, y expondremos sus problemas de escalabilidad, los cuales pretende resolver nuestra propuesta.

### II-A. Modelo

El modelo supone que la anotación depende de tres elementos: la dificultad del ejemplo a anotar, la experiencia del anotador y la verdadera etiqueta. Los dos primeros elementos se modelan de la siguiente forma:

- **Dificultad de cada ejemplo.** Se modela usando un parámetro,  $1/\beta_i \in [0, \infty)$ , para cada ejemplo  $i$ , donde  $\beta_i$  es positivo. Si  $1/\beta_i$  se acerca a 0, el ejemplo será más sencillo (anotadores con menos experiencia son capaces de anotarlos correctamente). Al contrario, si se acerca a  $\infty$ , el ejemplo sería tan ambiguo que incluso un anotador experimentado tendría solo un 50% de probabilidad de etiquetar el ejemplo incorrectamente.
- **Experiencia del anotador.** Se modela usando un parámetro,  $\alpha_j \in (-\infty, \infty)$ , para cada anotador  $j$ . Si  $\alpha_j$  se acercase a  $\infty$ , el anotador tendría tanta experiencia que siempre anotaría correctamente. Si  $\alpha_j$  se acercase a  $-\infty$  el anotador siempre anotaría incorrectamente, lo que significaría que el anotador es tan bueno como el anterior distinguiendo las clases, pero está invirtiendo la etiqueta, maliciosamente o por un malentendido. Por último, si  $\alpha_j$  se acerca a 0, significa que el anotador no puede discriminar entre las clases (podría ser un *spammer*).

El modelo de anotación (generativo), se vale de los dos parámetros anteriores de forma que la probabilidad de que un anotador etiquete una instancia correctamente es

$$c_{ji} = p(y_i^j = y_i | \alpha_j, \beta_i) = \frac{1}{1 + e^{-\alpha_j \beta_i}}$$

donde  $y_i^j$  es la anotación del anotador  $j$  a la instancia  $i$  e  $y_i$  es la etiqueta verdadera de la instancia. De esta forma, los anotadores más experimentados (con alto valor de  $\alpha_j$ ) tienen una mayor probabilidad de etiquetar correctamente. Asimismo, si la dificultad de un ejemplo,  $1/\beta_i$ , es mayor, la probabilidad de que la etiqueta sea correcta se acerca a 0,5. Esto ocurre también si el valor de  $\alpha_j$  se acerca a 0.

### II-B. Inferencia

Las variables observadas son las etiquetas generadas por los anotadores. Las variables ocultas son las verdaderas etiquetas y los parámetros del modelo de anotador  $\alpha$  y dificultad de las instancias  $\beta$ . Para estimar las variables ocultas se puede utilizar el enfoque *Expectation-Maximization* para obtener estimaciones por máxima verosimilitud:

- **Paso E:** Sea  $\mathcal{Y}_i = \{y_i^j\}$  el conjunto de anotaciones para el ejemplo  $i$  (no todos los anotadores tienen que anotar una instancia). Para obtener la probabilidad sobre

la verdadera etiqueta,  $y_i$ , conocidos los valores de  $\alpha$ ,  $\beta$  y las anotaciones  $\mathcal{Y}_i$  podemos utilizar:

$$p(y_i = k | \mathcal{Y}_i, \alpha, \beta) \propto p(y_i = k) \prod_j p_{ji}^k$$

donde

$$\begin{aligned} p_{ji}^k &= p(y_i^j = k | y_i, \alpha_j, \beta_i) \\ &= \begin{cases} (c_{ji})^k \cdot (1 - c_{ji})^{1-k} & \text{si } y_i = 1 \\ (c_{ji})^{1-k} \cdot (1 - c_{ji})^k & \text{si } y_i = 0 \end{cases} \end{aligned}$$

- **Paso M:** Se maximiza la siguiente función usando gradiente descendente con respecto a los valores de  $\alpha$  y  $\beta$

$$Q(\alpha, \beta) = \sum_i E[\ln(p(y_i = k))] + \sum_{ij} E[\ln(p_{ji}^k)],$$

donde  $E$  es la esperanza con respecto a las estimaciones procedentes del anterior paso E.

A partir de esta se obtienen los siguientes gradientes para cada parámetro

$$\frac{\partial Q}{\partial \alpha_j} = \sum_i (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_i)) \beta_i,$$

$$\frac{\partial Q}{\partial \beta_i} = \sum_j (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_i)) \alpha_j,$$

donde  $\sigma(x) = 1/(1 + e^{-x})$ .

### II-C. Pseudocódigo

A partir del modelado anterior podemos resumir el algoritmo mediante el pseudocódigo en el Algoritmo 1.

---

#### Algoritmo 1 Algoritmo GLAD sin optimización

---

- 1: **Paso E inicial:** Agregación por mayoría  $\rightarrow y_i$
- 2: **for**  $i = 0$  hasta converger **do**
- 3: **Paso M:** Optimizar mediante gradiente descendente usando las siguientes fórmulas:

$$\frac{\partial Q}{\partial \alpha_j} = \sum_i (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_i)) \beta_i,$$

$$\frac{\partial Q}{\partial \beta_i} = \sum_j (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_i)) \alpha_j,$$

- 4: **Paso E:** Estimar la probabilidad de la clase para cada instancia.

$$p(y_i = k | \mathcal{Y}_i, \alpha, \beta) \propto p(y_i = k) \prod_j p(y_i^j = k | y_i, \alpha_j, \beta_i)$$

- 5: **end for**
- 

El algoritmo comienza realizando una inicialización de las verdaderas etiquetas a la clase más frecuente presente en las anotaciones para cada ejemplo. Tras ello realiza varias iteraciones del algoritmo EM, estimando los parámetros del modelo en el paso M y volviendo a estimar la verdadera etiqueta en el paso E. Este algoritmo se detiene cuando se logra la convergencia de la función de verosimilitud o cuando se llega a un número máximo de iteraciones.



## II-D. Problemas de escalabilidad

Al intentar utilizar este algoritmo en problemas con un tamaño considerable descubrimos que el modelo pierde precisión en comparación con problemas similares de menor envergadura. Para comprobarlo, hemos realizado diferentes pruebas con el algoritmo variando el tamaño de los conjuntos de datos así como la tasa de aprendizaje del algoritmo de gradiente descendiente. Esta tasa gobierna en gran medida la capacidad del algoritmo para converger hacia una solución, en especial si mantenemos constantes el umbral y el número máximo de iteraciones del algoritmo de gradiente descendiente. Para las pruebas se han utilizado conjuntos de datos simulados con las siguientes características:

- **Tamaño del conjunto.** Se ha generado una serie de conjuntos de datos con los siguientes números de instancias<sup>1</sup>: 5000, 10000, 20000, 40000, 80000, 160000, 320000, 640000, 1280000, 2560000.
- **Anotaciones.** Para cada uno de los conjuntos anteriores se generan 10 anotaciones realizadas por anotadores simulados usando una distribución de probabilidad discreta. Usamos las distribuciones de la Figura 1, generando 6 anotadores con una precisión alta, 2 anotadores aleatorios y 2 anotadores adversarios.

Clase	Negativa	Positiva
Negativa	0.8	0.2
Positiva	0.1	0.9

(a) Precisión alta

Clase	Negativa	Positiva
Negativa	0.5	0.5
Positiva	0.5	0.5

(b) Aleatorio

Clase	Negativa	Positiva
Negativa	0.2	0.8
Positiva	0.8	0.2

(c) Adversario

Figura 1: Tipos de anotadores generados

Para cada conjunto de datos recogemos la precisión obtenida (al tener la información de la clase verdadera podemos evaluar directamente sobre ella) para cada conjunto de datos y 3 valores de la tasa de aprendizaje: 0.1, 0.01, 0.001. Resumimos los resultados en la Figura 2. Podemos observar que al aumentar el tamaño del conjunto de datos, la precisión del método parece disminuir. Variando la tasa de aprendizaje podemos conseguir resolver algunos casos más (aumentando el tiempo de aprendizaje).

Creemos que la razón fundamental de este problema es el aumento de parámetros que se estiman. En cuanto al modelo de anotador no hay problema, ya que en los conjuntos no varía

<sup>1</sup>Los datasets están disponibles en .csv y .parquet en el siguiente enlace: <http://bit.ly/caepia2018-cglad>

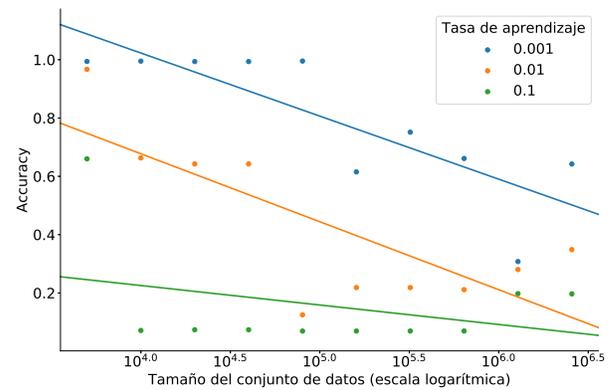


Figura 2: Problemas de escalabilidad del algoritmo GLAD.

el número de anotadores. Sin embargo, al aumentar el número de instancias del problema, aumenta de forma lineal el número de parámetros del modelo de dificultad (uno por instancia). Para tamaños de problema pequeños, como puede verse en la Figura 2, el algoritmo de gradiente descendiente converge, pero a medida que aumentamos el número de parámetros la convergencia es más compleja. Parece necesario, por tanto, reducir el número de parámetros del modelo de dificultad para conseguir un aprendizaje más estable y, sobre todo, para poder utilizar el algoritmo en contextos de grandes volúmenes de datos.

## III. CGLAD

En este artículo proponemos una mejora al algoritmo GLAD que permite reducir el número de parámetros necesarios para aprender el modelo. Para ello, añadimos un paso previo al algoritmo EM que reduce los parámetros mediante *clustering*.

### III-A. Modelo

El modelo usa la misma estructura que GLAD, pero calculando dificultades de *clusters* de instancias en vez de instancias concretas.

- **Dificultad de cada cluster.** Se modela usando un parámetro,  $1/\beta_t \in [0, \infty)$ , para cada *cluster*  $k$ , donde  $\beta_t$  es positivo. Si  $1/\beta_t$  se acerca a 0, los ejemplos que pertenecen al *cluster*  $t$  serán más sencillos, mientras que serán más ambiguos si se acerca a  $\infty$ .
- **Experiencia del anotador.** Se modela usando un parámetro,  $\alpha_j \in (-\infty, \infty)$ , para cada anotador  $j$ . El significado de este parámetro es el mismo que en el caso de GLAD.

El modelo de anotación es equivalente al caso de GLAD, pero utiliza el parámetro de dificultad del *cluster*. Si denotamos como  $\phi(i)$  la aplicación que mapea cada ejemplo  $i$  a uno de los *clusters*, el modelo de anotación sería el siguiente:

$$c_{ji} = p(y_i^j = y_i | \alpha_j, \beta_{\phi(i)}) = \frac{1}{1 + e^{-\alpha_j \beta_{\phi(i)}}}$$

donde  $y_i^j$  es la anotación del anotador  $j$  a la instancia  $i$  e  $y_i$  es la etiqueta verdadera de la instancia. Salvo por el uso del

*cluster* de dificultades, la interpretación de esta expresión es similar al caso de GLAD.

### III-B. Inferencia

Usamos el enfoque EM para aprender los parámetros del modelo (conocidos los *cluster* en los que se dividen las instancias). La interpretación de estos es similar al caso del algoritmo tradicional.

- **Paso E:** Sea  $\mathcal{Y}_i = \{y_i^j\}$  el conjunto de anotaciones para el ejemplo  $i$ . Para obtener la probabilidad sobre la verdadera etiqueta,  $y_i$ , conocidos los valores de  $\alpha$ ,  $\beta$  y las anotaciones  $\mathcal{Y}_i$  podemos utilizar:

$$p(y_i = k | \mathcal{Y}_i, \alpha_j, \beta_{\phi(i)}) \propto p(y_i = k) \prod_j p_{ji}^k$$

donde

$$\begin{aligned} p_{ji}^k &= p(y_i^j = k | y_i, \alpha_j, \beta_{\phi(i)}) \\ &= \begin{cases} (c_{ji})^k \cdot (1 - c_{ji})^{1-k} & \text{si } y_i = 1 \\ (c_{ji})^{1-k} \cdot (1 - c_{ji})^k & \text{si } y_i = 0 \end{cases} \end{aligned}$$

- **Paso M:** Se maximiza la siguiente función usando gradiente descendiente con respecto a los valores de  $\alpha$  y  $\beta$

$$Q(\alpha, \beta) = \sum_i E[\ln(p(y_i = k))] + \sum_{ij} E[\ln(p_{ji}^k)].$$

A partir de esta expresión se obtienen los siguientes gradientes para cada parámetro

$$\frac{\partial Q}{\partial \alpha_j} = \sum_i (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_{\phi(i)})) \beta_{\phi(i)},$$

$$\frac{\partial Q}{\partial \beta_t} = \sum_i \delta(\phi(i), t) \sum_j (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_t)) \alpha_j,$$

donde  $\delta(\phi(i), t) = 1$  si  $\phi(i) = t$  y 0 en otro caso.

### III-C. Inicialización

A diferencia del algoritmo GLAD, en la inicialización, aparte de obtener una estimación de las etiquetas verdaderas usando la clase de mayor frecuencia, debemos obtener los *clusters* para cada instancia  $\phi(i)$ . Para ello utilizamos un enfoque basado en factorización de matrices y K-Means.

- **Factorización de la matriz de anotación.** Al igual que en problemas donde se pueden aplicar técnicas de filtrado colaborativo, podemos visualizar la matriz de anotaciones como una matriz donde las filas representan a los anotadores y las columnas a los ejemplos. Podemos obtener dos matrices que nos permitan estimar esta usando factorización de matrices. Esto nos proporciona vectores de tamaño  $R$  (tamaño que debe elegir el usuario del método) que describen tanto a los anotadores como a los ejemplos. Para la factorización en esta propuesta usamos ALS [9], obteniendo dos matrices,  $A$  y  $D$ , que representan a los anotadores y a las instancias respectivamente.
- **Clustering.** Una vez obtenidos los vectores, podemos aplicar cualquier algoritmo de *clustering* sobre estos

para obtener agrupaciones sobre las instancias. Estas agrupaciones estarán basadas en las diferencias en los vectores encontrados en el apartado anterior, originados por patrones de anotación diferentes. Para este paso, en esta propuesta utilizamos K-Means, aunque se podrían utilizar otros métodos [6]. Como nuestro objetivo no es interpretar los *clusters*, si no simplemente utilizarlos para aliviar la complejidad de la inferencia, podemos utilizar un número de *clusters*  $K$  alto (su elección óptima dependerá del problema a resolver, en nuestro caso, para los experimentos, lo hemos fijado en 32).

Una vez completados los pasos anteriores, obtendríamos la función  $\phi$ , con la que ya tendríamos todos los componentes para implementar el algoritmo.

### III-D. Pseudocódigo

El pseudocódigo el algoritmo CGLAD se muestra en el Algoritmo 2

---

#### Algoritmo 2 Algoritmo CGLAD

---

- 1: **Inicialización:**
- 2:  $(A, D) = ALS(X)$
- 3:  $\phi(i) = KMeans(D)$
- 4: **Paso E inicial:** Agregación por mayoría  $\rightarrow y_i$
- 5: **for**  $i = 0$  hasta converger **do**
- 6: **Paso M:** Optimizar mediante gradiente descendiente:

$$\frac{\partial Q}{\partial \alpha_j} = \sum_i (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_{\phi(i)})) \beta_{\phi(i)},$$

$$\frac{\partial Q}{\partial \beta_t} = \sum_i \delta(\phi(i), t) \sum_j (p_{ji}^1 y_i^j + p_{ji}^0 (1 - y_i^j) - \sigma(\alpha_j \beta_t)) \alpha_j,$$

- 7: **Paso E:**

$$p(y_i = k | \mathcal{Y}_i, \alpha_j, \beta_i) \propto p(y_i = k) \prod_j p_{ji}^k$$

- 8: **end for**
- 

El algoritmo comienza aprendiendo los *clusters* dado el conjunto de anotaciones, pasando posteriormente al algoritmo EM para estimar los parámetros del modelo. Al igual que en GLAD, iteramos hasta que se produzca la convergencia o hasta realizar un máximo de iteraciones.

### III-E. Escalabilidad

Aplicamos este algoritmo a los mismos conjuntos de datos que utilizamos para analizar los problemas de escalabilidad del algoritmo GLAD. También usamos la misma configuración de parámetros para el algoritmo de gradiente descendiente y el algoritmo EM. Obtenemos los resultados que mostramos en la Figura 3. Como se puede ver, obtenemos un modelo más estable con respecto al tamaño de los conjuntos de datos. A diferencia del modelo original, obtenemos resultados aceptables para todos los conjuntos de datos y comparables a los resultados que obtiene GLAD en los problemas pequeños. Asimismo, se logra un algoritmo más estable con respecto a la elección de la tasa de aprendizaje.

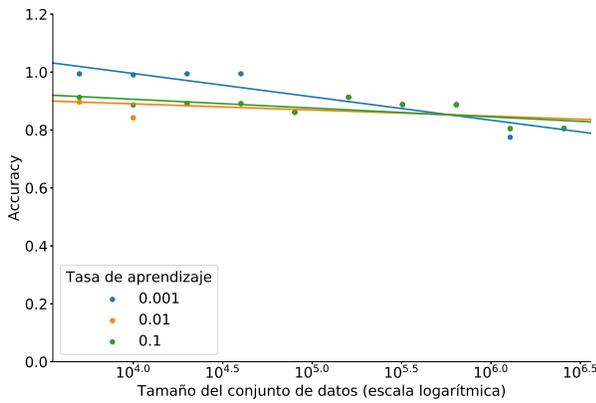


Figura 3: Escalabilidad en calidad del modelo en la propuesta CGLAD.

#### IV. COMPARATIVA

Hemos realizado varias comparativas tanto entre GLAD y nuestra propuesta, CGLAD, como entre nuestra propuesta y otros algoritmos presentes en la literatura.

##### IV-A. CGLAD contra GLAD

En esta sección comparamos tanto GLAD y CGLAD entre sí en términos de precisión, así como en tiempo de cómputo. Para esta comparativa utilizamos los mismos conjuntos de datos que se usaron para exponer los resultados de escalabilidad en las secciones anteriores. En la Tabla II se muestran los resultados obtenidos por ambos algoritmos en estos conjuntos. Como se puede ver en la tabla, nuestra propuesta obtiene mejores resultados en la mayor parte de los conjuntos de datos, especialmente cuando los tamaños de los conjuntos de datos son mayores. Para obtener estos resultados usamos la misma configuración para ambos algoritmos, con la salvedad de que, en el caso de CGLAD, tenemos que definir el tamaño de los vectores en la factorización, 8, y el número de *clusters*, que en nuestro caso es 32. El resto de parámetros, comunes, son los siguientes:

- Máximo número de iteraciones EM: 5.
- Threshold EM: 0.1
- Máximo número de iteraciones de gradiente descendiente: 100
- Threshold gradiente descendiente: 0.1
- Tasa de aprendizaje de gradiente descendiente: 0.001

También es interesante analizar el tiempo de ejecución para los cuatro primeros casos, que presentan una precisión similar. Esto se puede ver en la Tabla III.

Como se puede ver, a pesar de que nuestra propuesta presenta una precisión similar en los casos más pequeños, esta consigue un tiempo de ejecución mucho menor. Cabe decir que usamos los primeros casos, y no los posteriores, ya que al usar CGLAD el proceso de gradiente descendiente para optimizar parámetros, para casos más grandes el algoritmo GLAD no converge, lo que lleva a que el proceso pare tras pocas iteraciones. Para estos casos, nuestra propuesta (que

Instancias	Precision		F-score	
	CGLAD	GLAD	CGLAD	GLAD
5000	<b>0.9940</b>	<b>0.9940</b>	<b>0.9941</b>	<b>0.9941</b>
10000	0.9904	<b>0.9952</b>	0.9903	<b>0.9952</b>
20000	<b>0.9941</b>	0.9937	<b>0.9942</b>	0.9938
40000	<b>0.9941</b>	0.9937	<b>0.9942</b>	0.9938
80000	<b>0.8731</b>	0.8521	<b>0.8796</b>	0.8520
160000	<b>0.9132</b>	0.6151	<b>0.9191</b>	0.6153
320000	<b>0.8879</b>	0.7513	<b>0.8939</b>	0.7516
640000	<b>0.8873</b>	0.6613	<b>0.8974</b>	0.6566
1280000	<b>0.7750</b>	0.3077	<b>0.7500</b>	0.3086
2560000	<b>0.8056</b>	0.6423	<b>0.7844</b>	0.6418

Tabla II: Resultados GLAD y CGLAD

Instancias	CGLAD (Speedup)	GLAD
	5000	2797.0s (1.14)
10000	1862.0s (2.03)	3781.0s
20000	719.0s ( <b>5.52</b> )	3973.0s
40000	723.0s ( <b>5.43</b> )	3925.0s

Tabla III: Resultados en tiempo GLAD y CGLAD

sí optimiza los parámetros iterando) y GLAD no se pueden comparar.

##### IV-B. CGLAD contra otros algoritmos del área

Existen otros algoritmos en el área del aprendizaje a partir de múltiples anotadores que podrían ser interesantes para realizar una comparativa. Sin embargo, hay que tener en cuenta que estos no presentan información de la dificultad de los ejemplos como proporcionan GLAD y CGLAD. Específicamente, vamos a comparar nuestra propuesta con MajorityVoting, el algoritmo más sencillo, que únicamente consiste en utilizar la clase más frecuente y DawidSkene [1], que utiliza como modelo una matriz de confusión para cada anotador y el algoritmo EM para realizar la estimación de esta matriz y la clase verdadera. Para estas pruebas hemos generado otros conjuntos de datos con anotadores simulados, cuyas anotaciones no solo dependen de la clase verdadera de una instancia, si no también de la dificultad de cada instancia (generada aleatoriamente). Se han generado conjuntos de los siguientes tamaños: 5000, 10000, 20000, 40000 y 80000. Para la ejecución se utilizan los siguientes parámetros:

- Máximo número de iteraciones EM: 5.
- Threshold EM: 0.1
- Máximo número de iteraciones de gradiente descendiente: 100
- Threshold gradiente descendiente: 0.1
- Tasa de aprendizaje de gradiente descendiente: 0.0003
- Tamaño de los vectores para la factorización: 8
- Tamaño de los vectores para la factorización: 32

Podemos ver los resultados en la Tabla IV. Aunque CGLAD obtiene resultados comparables e incluso mejores en varios problemas, podemos ver que no es mejor sistemáticamente que el algoritmo de DawidSkene, siendo este último mucho más rápido y sencillo. Sin embargo, CGLAD no solo nos permite modelar la precisión de los anotadores sino también la dificultad de los ejemplos, lo que puede ser interesante en

muchos problemas, incluso aunque no se obtenga una mejora en la precisión del modelo.

Instancias	Métodos		
	MajorityVoting	DawidSkene	CGLAD
5000	0.8102	0.8462	<b>0.8610</b>
10000	0.8130	0.8443	<b>0.8469</b>
20000	0.8141	<b>0.8478</b>	0.8286
40000	0.8161	<b>0.8494</b>	0.8465
80000	0.8161	<b>0.8494</b>	0.8465

Tabla IV: Resultados de CGLAD con respecto a otros algoritmos del estado del arte

## V. CONCLUSIONES Y TRABAJO FUTURO

En este artículo proponemos una optimización al algoritmo GLAD para el aprendizaje a partir de múltiples anotadores donde mejoramos su escalabilidad y estabilidad a la hora de resolver problemas grandes, así como su tiempo de ejecución y, en gran parte de problemas, sus resultados. Para comprobarlo se han realizado varios experimentos que permiten comparar ambos modelos tanto en problemas con conjuntos de datos relativamente pequeños como en conjuntos de datos grandes, donde GLAD no obtiene buenos resultados. Como se ha visto en la experimentación, para este tipo de problemas nuestra propuesta funciona mejor y es más robusta ante cambios en la tasa de aprendizaje. También se ha llevado a cabo una comparativa entre nuestra propuesta y otros algoritmos del área. Se ha observado que, aunque nuestra propuesta obtiene resultados comparables a otros algoritmos del estado del arte en varios problemas, existen otros algoritmos que por su simplicidad habría que considerar a la hora de resolver un problema a partir de múltiples anotadores si el único objetivo es realizar la estimación de la verdadera etiqueta. En contrapartida, si, aparte de la precisión en la estimación de la verdadera clase, es de interés estimar la dificultad de las instancias (porque es necesaria esta información o porque en el problema que afrontamos tiene importancia la dificultad de las instancias a la hora de estimar) nuestra propuesta es una alternativa más que adecuada al algoritmo GLAD, sobre todo si queremos abordar problemas con un número de instancias relativamente elevado.

Esta mejora, así como el análisis de los problemas de este algoritmo, abren alternativas a futuras líneas de trabajo. Por un lado, en este artículo solo utilizamos algoritmos sencillos tanto para la factorización como para el *clustering*. Existen multitud de técnicas de *clustering* más potentes que podrían ser de interés para mejorar los resultados del algoritmo. Asimismo, también podría ser de interés aplicar la idea de la dificultad de los ejemplos a otros algoritmos existentes en el área pero con mejores características que GLAD en lo que respecta a la escalabilidad así como a la capacidad de abordar problemas de clase discreta o, incluso, continua. Por último, destacar que esta propuesta solo utiliza las anotaciones para realizar el *clustering* y, posteriormente, la estimación. En problemas donde las características de cada instancia estén disponibles, podría ser interesante utilizarlas, junto con las anotaciones,

para elaborar *clusters* más informados, lo que a nuestro juicio podría influir positivamente en la estimación final de la clase verdadera.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por la Agencia Estatal de Investigación (AEI) y el Fondo Europeo de Desarrollo Regional (FEDER, UE) mediante los proyectos TIN2016-77902-C3-1-P y TIN2016-82013-REDT. Enrique G. Rodrigo también ha sido financiado por el MECD mediante la beca FPU15/02281.

## REFERENCIAS

- [1] Alexander Philip Dawid and Allan M Skene. Maximum likelihood estimation of observer error-rates using the em algorithm. *Applied statistics*, 2:20–28, 1979.
- [2] Jerónimo Hernández-González, Inaki Inza, and Jose A Lozano. Weak supervision and other non-standard classification problems: a taxonomy. *Pattern Recognition Letters*, 69:49–55, 2016.
- [3] Qi Li, Yaliang Li, Jing Gao, Bo Zhao, Wei Fan, and Jiawei Han. Resolving conflicts in heterogeneous data by truth discovery and source reliability estimation. In *Proceedings of the 2014 ACM SIGMOD international conference on Management of data*, pages 1187–1198. ACM, 2014.
- [4] Vikas C Raykar, Shipeng Yu, Linda H Zhao, Gerardo Hermosillo Valadez, Charles Florin, Luca Bogoni, and Linda Moy. Learning from crowds. *Journal of Machine Learning Research*, 11(Apr):1297–1322, 2010.
- [5] Jacob Whitehill, Ting-fan Wu, Jacob Bergsma, Javier R Movellan, and Paul L Ruvolo. Whose vote should count more: Optimal integration of labels from labelers of unknown expertise. In *Advances in neural information processing systems*, pages 2035–2043, 2009.
- [6] Rui Xu and Donald Wunsch. Survey of clustering algorithms. *IEEE Transactions on neural networks*, 16(3):645–678, 2005.
- [7] Jing Zhang, Xindong Wu, and Victor S Sheng. Learning from crowdsourced labeled data: a survey. *Artificial Intelligence Review*, 46(4):543–576, 2016.
- [8] Yudian Zheng, Guoliang Li, Yuanbing Li, Caihua Shan, and Reynold Cheng. Truth inference in crowdsourcing: is the problem solved? *Proceedings of the VLDB Endowment*, 10(5):541–552, 2017.
- [9] Yunhong Zhou, Dennis Wilkinson, Robert Schreiber, and Rong Pan. Large-scale parallel collaborative filtering for the netflix prize. In *International Conference on Algorithmic Applications in Management*, pages 337–348. Springer, 2008.



# Análisis preliminar de marcos tecnológicos en data stream

Fernando Puentes, María Dolores Pérez-Godoy, Pedro González, María José Del Jesus

Departamento de Informática  
Universidad de Jaén  
{fpuentes; lperez; pglez; mjjesus}@ujaen.es

**Abstract**—El análisis de datos en tiempo real está adquiriendo cada vez más importancia para ayudar en la toma de decisiones. Existen herramientas de código abierto y propietarias para el análisis de flujos continuos de datos. En este trabajo se analizan herramientas tanto para la recolección de datos de diversas fuentes como para el procesamiento de los mismos, presentando sus características más importantes con el objetivo de ayudar en la toma de decisión respecto al marco tecnológico en el desarrollo de métodos de minería de datos para *data stream*.

**Keywords**— *Streaming; Big Data; Minería de datos; Procesamiento de data stream; Recolección de datos;*

## I. INTRODUCCIÓN

La minería de datos [1] se ha centrado tradicionalmente en analizar conjuntos de datos almacenados y estáticos en ambientes de procesamiento por lotes (modo *batch*). Sin embargo, cada día existen más fuentes que generan enormes cantidades de datos de forma continua, muchas veces asociados a problemas de *big data*, siendo necesario su procesamiento conforme llegan al sistema sin tener que almacenarlos (modo *streaming* o de flujo de datos).

Cada fuente va a generar un flujo de datos (*stream*) que tiene las siguientes características [2]:

- Los datos fluyen continuamente. Siempre se están generando datos, normalmente a alta velocidad.
- La distribución de los datos puede cambiar con el tiempo (cambio de concepto [3]). Debemos detectar estos cambios para poder responder a ellos lo antes posible.
- La velocidad con la que se generan los datos puede variar con el tiempo, por lo que unas veces llegarán más datos y otras menos.
- El tamaño del *stream* es teóricamente infinito, por lo que no puede ser totalmente almacenado en memoria para su procesamiento.

En los últimos tiempos, han ido apareciendo herramientas para facilitar el tratamiento de los *streams* de manera distribuida, tanto de código abierto como propietarios. La Fig. 1 muestra el esquema general de las etapas necesarias para el análisis de un *stream*. El proceso puede dividirse en 3 etapas [4]: recolección y pre-procesamiento; procesamiento; y análisis y evaluación.



Fig. 1. Esquema general análisis en stream

En la primera etapa se utilizará una herramienta que sea capaz de realizar la recolección continua de los datos generados por una o varias fuentes. También debemos asegurarnos de que los datos estén en el formato correcto antes de pasar a la siguiente etapa, por lo que será necesario llevar a cabo un pre-procesamiento, utilizando técnicas de reducción de la dimensionalidad (reducción de características y/o de instancias) y simplificación del espacio de características [8].

Una vez que los datos han sido recolectados y pre-procesados y tienen el formato correcto, podemos pasar a la segunda etapa, el procesamiento. En esta etapa se utiliza un algoritmo de minería de datos para analizar el *stream* y llevar a cabo la extracción de conocimiento. Para mejorar el rendimiento se puede elegir una herramienta que permita realizar un procesamiento distribuido y que se adapte mejor a los requisitos y necesidades del problema a resolver.

La tercera y última etapa (cuya realización es opcional) se encarga de la visualización de los resultados obtenidos en la etapa anterior mediante alguna herramienta de visualización en tiempo real.

Aunque existen herramientas propietarias y de código abierto, en este trabajo nos centraremos fundamentalmente en las de código abierto, puesto que permiten poner el conocimiento obtenido al alcance de toda la comunidad investigadora y son cada vez más utilizadas [7]. En particular, en este trabajo se analizan herramientas que desarrollan las 2 primeras etapas, aportando información que facilite la elección de la herramienta a utilizar en función del objetivo a alcanzar.

El trabajo está organizado de la siguiente forma. En la sección 2, se detalla la etapa de recopilación y pre-procesamiento de datos y se revisan las herramientas más destacadas. En la sección 3, se introduce la etapa de procesamiento y se analizan las herramientas de esta categoría. En la sección 4, se reflejan las conclusiones obtenidas.

## II. ETAPA DE RECOLECCIÓN Y PRE-PROCESAMIENTO

Antes de procesar los datos suele ser necesario recopilarlos, ya que es habitual que sean generados por diferentes fuentes simultáneas, y es necesario unificarlos para disponer de un único canal de entrada al procesamiento. Además hay que llevar a cabo un pre-procesamiento de los datos, que permita que la etapa de procesamiento reciba los datos de forma adecuada. El objetivo de esta sección es analizar y comparar diferentes herramientas para realizar estas tareas, destacando sus características principales.

### A. Apache Kafka

Apache Kafka<sup>1</sup> es una plataforma de *streaming* distribuida que permite recopilar datos de diversas fuentes mediante una metodología de publicación/subscripción (el productor publica los datos y el consumidor se suscribe para recibirlos), similar a una cola de mensajes. Así, se deben definir en el clúster de Kafka un conjunto de *topics*, en los que el productor publica los mensajes, para que después un consumidor pueda recoger los datos que se van almacenando en los *topics* que se seleccionen. Estos datos se mantienen durante un tiempo (denominado periodo de retención), siendo eliminados cuando finaliza el mismo.

Los datos que se almacenan en los *topics* son pares clave-valor en formato texto, en los que la clave suele ser algún tipo de marca de tiempo (*timestamp*) y el valor el dato correspondiente. Para llevar a cabo un pre-procesamiento hay 2 opciones: hacer el pre-procesamiento en el productor o construir un consumidor-productor. La primera opción consistiría en un programa que transforme los datos antes de enviarlos y la segunda sería una aplicación que escuche un *topic*, capture todo lo que llegue a ese *topic* para transformarlo y envíe por último el resultado a otro *topic* diferente.

Las características ms importantes de Kafka se muestran en la TABLA I. Algunos puntos a destacar son:

- Tiene compatibilidad con todas las herramientas de procesamiento analizadas en este trabajo.
- Es necesario implementar un programa productor y otro consumidor, en alguno de los lenguajes soportados.
- Se dispone de una extensa documentación para desarrolladores y muchos problemas resueltos.
- No tiene una utilidad nativa para monitorizar, pero hay alguna aplicación de terceros que si lo permite, como Burrow de LinkedIn.
- Kafka es la plataforma más utilizada, ya que permite replicar y pre-procesar los datos. Además, su política de publicación/subscripción permite tener varios almacenamientos diferentes, por lo que al procesar los datos podemos elegir de qué *topic* obtenerlos, e incluso tener varias aplicaciones obteniendo datos del mismo sistema que ejecuta Kafka.

<sup>1</sup> <https://kafka.apache.org>

### B. Apache Flume

Apache Flume<sup>2</sup> es un servicio distribuido que permite recolectar, agregar y mover eficientemente grandes cantidades de *logs*. Tiene una arquitectura simple y flexible basada en flujos de datos continuos. Se basa en un agente compuesto por 3 componentes: una fuente, un canal y un destino.

La fuente consume los datos de una fuente externa, como un servidor web. Esta fuente envía datos a Flume en un formato conocido por la fuente. Cuando la fuente recibe un evento, éste es almacenado en uno o más canales. Un canal es un almacén pasivo que almacena eventos hasta que son consumidos por el destino. Flume dispone de diferentes tipos de canales, dependiendo del tipo de almacenamiento que se utilice. Finalmente, el destino de los datos es el responsable de eliminar un evento del canal y ponerlo en el sistema de ficheros destino. La fuente y el destino se ejecutan asincrónicamente con los eventos organizados en el canal. Hasta que un dato no se almacena en el sistema de ficheros destino, no se elimina del canal.

Las características generales más importantes de Flume se muestran en la TABLA I. Algunos puntos a destacar son:

- Se suele utilizar con Kafka (Flafka) como canal, de forma que ya no habría que implementar el productor y el receptor.
- Flume no permite replicar los datos, por lo que se suele utilizar para transportar grandes cantidades de datos de un sistema a otro.

### C. Apache Nifi

Apache Nifi<sup>3</sup> es un software que permite migrar los datos de un sistema de ficheros a otro. Los datos pueden ser procesados mediante una serie de operaciones para transformarlos antes de ser enviados al destino. Cuenta con una interfaz de usuario para el navegador web, que facilita la creación de flujos y la configuración de cada una de las acciones. Nifi dispone de distintos componentes: *processor*, *reportingTask*, *controllerService*, *flowFilePrioritizer* y *authorityProvider*.

El *processor* es el componente más utilizado. Permite crear, eliminar, modificar o inspeccionar datos (denominados *flowFiles*), que incluyen un contenido y una serie de atributos que actúan como metadatos. Podemos hacer pasar los datos por diferentes *processors* para pre-procesar los datos y finalmente enviarlos al destino.

Las características ms importantes de Nifi se muestran en la TABLA I. Algunos puntos a destacar son:

- No necesita programar nada, ya que todo se configura en la interfaz.
- Permite realizar transformaciones sobre los datos, como conversión de datos/formatos, delegación de funcionalidades y operaciones de unión y difusión de los datos.

<sup>2</sup> <https://flume.apache.org>

<sup>3</sup> <https://nifi.apache.org>



- Se suele utilizar con Kafka, de forma que ya no habría que implementar el productor y el receptor.
- Permite monitorizar el estado del flujo en tiempo real, identificando posibles errores.
- Permite el envío de datos a múltiples destinos a la vez.
- Nifi no permite replicar los datos pero tiene una interfaz gráfica, por lo que se suele utilizar cuando se necesita mover datos de un sitio a otro y gestionar los *streams* de datos.

#### D. Otras herramientas de recolección

Aunque las herramientas de recolección descritas hasta ahora son de código abierto, existen otras herramientas propietarias, como Alooma o Attunity Replicate.

Alooma permite tener visibilidad y control sobre los datos, debido a su interfaz gráfica. Alooma recopila, en tiempo real, los datos de varias fuentes de datos y las unifica para aportarlas al sistema de procesamiento.

Attunity Replicate permite a las organizaciones acelerar la replicación de datos, la recolección y el *streaming* a través de diferentes bases de datos heterogéneas, almacenes de datos y plataformas de *big data*. Attunity Replicate mueve fácilmente los datos, de forma segura y eficiente.

TABLA I. CARACTERÍSTICAS DE LAS HERRAMIENTAS DE RECOLECCIÓN

Características	Herramienta		
	Kafka	Flume	Nifi
Última versión	1.1.0	1.8.0	1.6.0
Fecha última modificación	28/03/2018	04/05/2018	08/04/2018
Pre-procesamiento	Si	Si	Si
Garantía de entrega	Al menos una	Al menos una	Al menos una
Tolerante a fallos	Si	Si	Si (solo con "FileChannel")
Lenguajes de programación	Java	Java	Java
Tiene una utilidad de monitorización	No <sup>a</sup>	No	Si
Plataformas	Windows Linux	Windows Linux	Windows Linux Mac OS
Documentación	Extensa	Extensa	Extensa
Replicación de datos	Si	No	No

<sup>a</sup>Ver información en el punto II.A

### III. ETAPA DE PROCESAMIENTO

Una vez que se han recopilado y pre-procesado los datos, están listos para ser procesados con algún algoritmo de *streaming*. En esta sección vamos a analizar y comparar diferentes herramientas de procesamiento, destacando sus características principales. En [5] y [6] se pueden encontrar comparativas de rendimiento entre algunas de las herramientas más conocidas, como Spark, Storm y Flink.

A la hora de procesar los datos, hay que elegir de qué forma vamos a tratar los datos, utilizando alguno de los 3 tipos de garantías de procesamiento disponibles:

- Como máximo una vez: Los datos pueden ser procesados una vez o ninguna.
- Al menos una vez: Los datos pueden ser procesados 1 o más veces. Nunca tendremos datos sin procesar.
- Exactamente una vez: Los datos serán procesados una sola vez. No hay ni duplicados, ni datos no procesados.

#### A. Apache Spark Streaming

Apache Spark Streaming<sup>4</sup> es una extensión del núcleo (*core*) de Spark que permite procesamiento escalable, de alto rendimiento y tolerante a fallos de *streams* de datos. Los datos llegan a través de uno o varios *streams* de entrada que pueden ser procesados usando algoritmos complejos expresados con funciones a alto nivel como *map*, *reduce*, *join* y *window*. Finalmente, los datos procesados pueden ser transferidos a un sistema de ficheros o una base de datos.

Spark Streaming trabaja de la siguiente forma. Recibe un *stream* de entrada de datos y lo divide en *batches*, todos del mismo tiempo (todos los datos que lleguen en un determinado tiempo se tendrán en cuenta). Después, cada *batch* es procesado por el *Spark Engine* mediante algún algoritmo, generando a la salida un *batch* por cada *batch* de entrada.

Las principales características se muestran en la TABLA II. Algunos puntos a destacar son:

- Puede analizar los datos en modo *batch* o en modo *streaming* (una adaptación del modo *batch* en el que el *stream* se divide en *batches*).
- Permite la utilización de ventanas temporales. Éstas tienen un tamaño de ventana y un desplazamiento que debe ser múltiplo del intervalo de *batch*.
- La latencia es mayor que en otras herramientas, ya que no realiza un procesamiento continuo de los datos, sino que tiene que esperar siempre a que se cumpla el tiempo de un *batch*.
- Spark Streaming es útil en aquellos casos en los que necesitamos procesar datos por lotes en modo *batch* o en modo *streaming*. Además, la existencia de librerías de algoritmos, su extensa documentación y su activa comunidad pueden ser factores por los que elegir esta herramienta.

#### B. Apache Spark Structured Streaming

Apache Spark Structured Streaming<sup>5</sup> es un motor de procesamiento de *stream* escalable y tolerante a fallos construido sobre el motor de *Spark SQL*, lo que permite procesar un *stream* de manera similar a como se hace en el modo *batch* sobre datos estáticos. Structured Streaming permite hacer consultas que se resuelven incrementalmente,

<sup>4</sup> <https://spark.apache.org>

<sup>5</sup> <https://spark.apache.org/docs/2.3.1/streaming-programming-guide.html>

actualizando el resultado final, que se almacena en una tabla de salida.

En el modo *streaming*, hay una tabla ilimitada (*dataset*) a la que se van añadiendo los datos conforme llegan por el *stream*. Sobre esta tabla se realizan las consultas incrementales. Estas consultas procesan los datos en *micro-batches* de 100 milisegundos, aunque en la nueva versión 2.3 de Spark se ha introducido un modo continuo, denominado “Procesamiento continuo”, que permite latencias por debajo de 1 milisegundo con garantías de procesamiento de “al menos una vez”, pero es una característica experimental aún en desarrollo.

Las principales características se muestran en la TABLA II. Algunos puntos a destacar son:

- Permite procesamiento en modo *batch* y en modo *streaming*.
- En el momento de actualizar la salida hay 3 modos: *complete*, *append* y *update*. Dependiendo del tipo de consulta se podrá utilizar uno u otro.
- En otros modelos, el usuario tiene que mantener y actualizar las agregaciones ejecutadas. En este modelo, Spark es el que se encarga de mantener y actualizar las tablas con los nuevos datos.
- Permite utilizar ventanas temporales igual que Spark Streaming, con la diferencia de que aquí no hay que especificar el intervalo de *batch*.
- Junto con las ventanas temporales se puede utilizar lo que se conoce como *watermark*, que establece un límite para los datos que lleguen con retraso, basándose en un campo *timestamp*. Si un dato llega con retraso, se actualizan los valores de su instante temporal correspondiente y no en el que llega el dato.
- No dispone de ninguna librería con algoritmos de minería de datos, aunque si hay algunas implementaciones en GitHub.
- Spark Structured Streaming es útil en aquellos casos relacionados con consultas a bases de datos, gracias a sus consultas incrementales sobre los datos que llegan. Además, la utilización de *watermarks* con ventanas temporales pueden ser factores por los que elegir esta herramienta.

### C. Apache Storm

Apache Storm<sup>6</sup> es un sistema de computación distribuida en tiempo real que procesa los datos de entrada dato a dato. Storm trabaja por topologías, de forma que el flujo va a ir pasando por una serie de nodos/operaciones hasta llegar al final de la topología. En una topología Storm existen dos tipos de nodos: Spout, que regulan la entrada de datos al sistema, y Bolt, que realizarán operaciones sobre los datos.

Storm tiene un modo de funcionamiento utilizando una abstracción superior denominada Trident, lo que permite que pueda procesar los datos por lotes (*batch*). Este modo ofrece garantías de procesamiento de “exactamente una vez”, aunque

<sup>6</sup> <http://storm.apache.org>

aumenta la latencia al tener que esperar para recopilar un conjunto de datos.

La TABLA II muestra las principales características de Storm. Algunos puntos a destacar son:

- Solo permite procesamiento en modo *streaming*, dato a dato.
- No garantiza que los datos se procesen en orden.
- Permite la utilización de ventanas temporales y, junto a estas, se pueden utilizar *watermarks*.
- No dispone actualmente de ninguna librería con algoritmos de minería de datos, aunque hay en desarrollo una denominada SAMOA<sup>7</sup>.
- Storm es útil en aquellos casos en los que se van a repartir las tareas por nodos según una topología y queremos procesar los datos dato a dato con garantías de procesamiento de “al menos una vez”.

### D. Apache Flink

Apache Flink<sup>8</sup> es un *framework* de procesamiento para aplicaciones de *streaming* de datos distribuidas que permite procesar los datos dato a dato o en *micro-batches*. También permite el procesamiento en modo *batch*, con un conjunto de datos estático. Funciona por topologías, al igual que Storm, en las que hay 3 tipos de nodos: operadores, fuentes y destinos. Los datos entrarán por los nodos fuente al sistema, serán procesados mediante diferentes nodos operadores y el resultado será depositado en un destino.

Flink es muy potente en cuanto al uso de ventanas, ya que permite una gran variedad. Las ventanas pueden estar basadas en número de eventos o en tiempo. Dentro de una ventana también se permite distinguir entre eventos de diferentes tipos. Hay diferentes tipos de ventana ya implementadas, pero se ofrece la posibilidad de implementar una ventana personalizada si fuese necesario.

Las características principales se muestran en la TABLA II. Algunos puntos a destacar son:

- Su mayor ventaja es la variedad de ventanas, que además permiten la utilización de *watermarks* para permitir un retardo en los datos de entrada.
- Permite procesar los datos en modo *streaming* y en modo *batch*. Además, se puede elegir entre procesar los datos de uno en uno o por lotes.
- Flink es útil en casos en los que queremos procesar los datos dato a dato o por lotes con garantías de procesamiento de “exactamente una vez”, en modo *batch* o en modo *streaming*. Flink es muy similar a Storm, pero proporciona funcionalidades que en Storm habría que implementar. Además, la posibilidad de utilizar ventanas temporales junto con *watermarks* o de un tamaño concreto puede ser un factor importante por el que elegir esta herramienta.

<sup>7</sup> <https://samoa.incubator.apache.org>

<sup>8</sup> <https://flink.apache.org>



### E. Apache Samza

Apache Samza<sup>9</sup> es un *framework* de procesamiento distribuido de *stream* que utiliza Kafka y YARN en el proceso. Samza ofrece muchas funcionalidades similares a Storm y procesa *streams* de datos mediante tareas predefinidas, que realizan alguna operación en el *stream* de datos. Una aplicación Samza es un flujo de datos que consiste en consumidores que obtienen datos que son procesados por un grafo de trabajos, donde cada trabajo contiene una o más tareas. En Samza cada trabajo es una entidad que puede ser desplegada, iniciada o parada inmediatamente.

En Samza, cada tarea contiene un almacén clave-valor usado para almacenar el estado. Los cambios en este almacén son replicados a otras máquinas del clúster para permitir a las tareas ser recuperadas rápidamente en caso de fallo.

Las características de Samza se muestran en la TABLA II. Algunos puntos a destacar son:

- Garantiza que los mensajes son procesados en orden.
- No dispone de una librería con algoritmos de minería de datos, aunque en el futuro podrá utilizar algoritmos de SAMOA.
- Utiliza procesos *single-thread*.
- Samza es útil en casos en los que necesitamos procesar los datos dato a dato, en modo *batch* o modo *streaming*. Samza se ha realizado sobre Kafka, por lo que los datos se van a almacenar en particiones y se asegura que van a ser procesados en orden.

### F. Apache Apex

Apache Apex<sup>10</sup> es una plataforma de procesamiento basada en YARN nativo de Hadoop. Apex proporciona un API simple, que permite a los usuarios escribir código genérico y reusable. El código se coloca como está y la plataforma automáticamente maneja las cuestiones operativas, como gestión de estados, tolerancia a fallos, escalabilidad, seguridad, métricas, etc. Esto permite que los usuarios se centren en el desarrollo.

El núcleo de la plataforma de Apex es complementado por Malhar, una librería de funciones lógicas y conectores. Proporciona acceso a diferentes sistemas de ficheros, sistemas de mensajes y bases de datos.

Las características principales se muestran en la TABLA II. Algunos puntos a destacar son:

- La topología de Apex es un grafo acíclico dirigido, cuyos nodos son Operators, y los arcos son los *streams*.
- Los datos se procesan dato a dato, aunque también soporta procesamiento por lotes de un determinado tiempo.
- No dispone de una librería con algoritmos de minería de datos, aunque en el futuro podrá utilizar algoritmos de SAMOA.

- Apex es útil en casos en los que necesitamos procesar los datos dato a dato con garantías de procesamiento de “exactamente una vez” y se quiere crear y utilizar código que sea reutilizable. Además tiene compatibilidad con la librería Malhar, que puede ser un factor importante para elegir esta herramienta.

### G. Apache Beam

Apache Beam<sup>11</sup> es un *framework* de procesamiento de *streams* que permite definir un procesamiento independientemente del sistema de procesamiento de datos (denominado *runner*) que se utilice. Permite seguir utilizando el mismo procesamiento programado, permitiendo cambiar el *runner*. Permite utilizar los siguientes *runners*: Apache Apex, Apache Flink, Apache Spark, Apache Gearpump y Google Cloud Dataflow.

Sus características se muestran en la TABLA II. Algunos puntos a destacar son:

- La garantía de procesamiento depende del *runner* que se utilice para procesar los datos, ya que cada uno ofrece unas garantías propias de la herramienta.
- Se puede utilizar como lenguaje de programación Java y Python, aunque también hay una API de Scala en un proyecto de GitHub<sup>12</sup>.
- La latencia varía según el *runner* que se utilice.
- Beam es útil en casos en los que se quiere probar un procesamiento con diferentes *runners* para ver cual se adapta mejor.

### H. Otras herramientas de procesamiento

Aunque todas las herramientas de procesamiento analizadas aquí son de código abierto, existen otras herramientas propietarias, como Amazon Kinesis o Google Cloud Dataflow. Estas herramientas ofrecen soporte, mayor seguridad y herramientas avanzadas como entornos de desarrollo e interfaces orientadas al negocio [7].

Amazon Kinesis permite procesar y analizar datos a medida que se reciben y es capaz de ofrecer una respuesta instantánea en lugar de tener que esperar a la recopilación de datos. Una vez procesados los datos, Kinesis ofrece también herramientas para visualizar los resultados mediante gráficas o tablas.

Google Cloud Dataflow es un servicio de procesamiento de datos administrado capaz de ejecutar canalizaciones, tanto en modo *batch* como en modo *streaming*. Utiliza un modelo de programación unificado e incluye SDKs para definir flujos de procesamiento de datos.

Finalmente, hay una herramienta llamada Apache Gearpump, que aún está en desarrollo (*incubating*). Gearpump es un motor de procesamiento de *streaming* basado en eventos/mensajes que está inspirado en los avances recientes en el *framework* de Akka.

<sup>9</sup> <http://samza.apache.org>

<sup>10</sup> <https://apex.apache.org>

<sup>11</sup> <https://beam.apache.org>

<sup>12</sup> <https://github.com/spotify/scio>

#### IV. CONCLUSIONES

En este trabajo se han analizado diferentes herramientas tanto para recolectar datos de las fuentes que los generan como para procesarlos. Cada herramienta tiene ventajas e inconvenientes según la situación, por lo que sus características serán factores clave a la hora de seleccionar la herramienta más apropiada para nuestro objetivo.

En cuanto a recolección de datos, la herramienta más completa es apache Kafka, ya que tiene un gran rendimiento para esta tarea y permite pre-procesar los datos. También permite replicar los datos, lo que aumenta considerablemente la tolerancia a fallos. Además, Kafka puede recopilar datos para diferentes aplicaciones a la vez, ya que se pueden distinguir por un *topic* diferente. Por último, esta herramienta está siendo muy utilizada y dispone de gran cantidad de documentación y problemas resueltos para ayudar a los desarrolladores.

En cuanto a procesamiento, actualmente la mejor herramienta es Apache Spark Streaming por su gran rendimiento, a pesar de que tiene algo de latencia. Además, tiene garantías de procesamiento de “exactamente una vez” y tiene algunas librerías con algoritmos ya implementados, tanto en modo *batch* como en modo *streaming*, lo que puede ayudar a los desarrolladores a la hora de implementar nuevos algoritmos. También tiene compatibilidad con Kafka, por lo que se pueden utilizar ambos para las etapas correspondientes. Por último, esta herramienta también está siendo ampliamente

utilizada y dispone de gran cantidad de documentación útil para los desarrolladores, evitando tener que invertir mucho tiempo para resolver problemas.

#### AGRADECIMIENTOS

Este trabajo ha sido subvencionado por el Ministerio de Economía y Competitividad bajo el proyecto TIN2015-68454-R, Fondos FEDER.

#### REFERENCIAS

- [1] J. Han, M. Kamber y J. Pei. Data Mining: Concepts and Techniques, 3rd Edition. Morgan Kaufmann, 2011
- [2] J. Gama. Knowledge Discovery from Data Streams. Chapman & Hall/CRC, 2010
- [3] I. Khamassi, M. Sayed-Mouchaweh, M. Hammami, K. Ghédira. Discussion and review on evolving data streams and concept drift adapting. Evolving Systems 9:1–23, 2018
- [4] Ms.D.Jayanthi, Dr.G.Sumathi. A Framework for Real-time Streaming Analytics using Machine Learning Approach. In: Proceedings of National Conference on Communication and Informatics-2016
- [5] J. Samosir, M. Indrawan-Santiago, P. D. Haghghi. An evaluation of data stream processing systems for data driven applications. Procedia Computer Science 9:439-449, 2016
- [6] Y. Wang. Stream Processing Systems Benchmark: StreamBench. Ph. D. dissertation. Aalto University, School of Science, 2016
- [7] Gartner. Market Guide for Event Stream Processing (G00332885), 2018
- [8] S. Ramírez-Gallego, B. Krawczyk, S. García, M. Wozniak, F. Herrera. A survey on data preprocessing for data stream mining: Current status and future directions. Neurocomputing 239:39-57, 2017

TABLA II. PRINCIPALES CARACTERÍSTICAS DE LAS HERRAMIENTAS DE PROCESAMIENTO

Características	Herramientas						
	<i>Spark Streaming</i>	<i>Spark Structured Streaming</i>	<i>Storm</i>	<i>Flink</i>	<i>Samza</i>	<i>Apex</i>	<i>Beam</i>
Última versión	2.3.1	2.3.1	1.2.2	1.5.0	0.14.1	3.7.0	2.4.0
Fecha última modificación	08/06/2018	08/06/2018	04/06/2018	25/05/2018	18/05/2018	27/04/2018	20/03/2018
Garantía de procesamiento	Exactamente una vez	Exactamente una vez	Al menos una vez / Exactamente una vez	Exactamente una vez	Al menos una vez	Exactamente una vez	Depende <sup>a</sup>
Tolerante a fallos	Si	Si	Si	Si	Si	Si	Si
Lenguajes de programación	Java Scala Python R	Java Scala Python R	Java Scala Python Ruby	Java Scala Python	Java	Java	Java Scala <sup>a</sup> Python
Utilidad de monitorización	Si	Si	Si	Si	Si	Si	Si
Plataformas	Windows Linux Mac OS	Windows Linux Mac OS	Windows Linux	Windows Linux Mac OS	Linux	Windows Linux Mac OS	Windows Linux Mac OS
Documentación	Muy extensa	Extensa	Extensa	Extensa	Poca	Poca	Extensa
Modificaciones durante la ejecución	No	No	Si	No	No	Si	No
Latencia	Segundos	Milisegundos	Milisegundos	Milisegundos	Milisegundos	Milisegundos	Depende <sup>a</sup>
Procesamiento modo batch	Si	Si	Si <sup>a</sup>	Si	Si	No	Si
Procesamiento modo streaming	Si	Si	Si	Si	Si	Si	Si
Librería Minería de Datos	MLLIB streamDM Amidst Toolbox	No <sup>a</sup>	SAMOA <sup>a</sup>	FlinkML SAMOA Amidst Toolbox	SAMOA <sup>a</sup>	SAMOA <sup>a</sup>	Si <sup>a</sup>

<sup>a</sup>. Ver información en el punto correspondiente



# Selección de características escalable con ReliefF mediante el uso de Hashing Sensible a la Localidad

Carlos Eiras-Franco  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
carlos.eiras.franco@udc.es

Bertha Guijarro-Berdiñas  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
cibertha@udc.es

Amparo Alonso-Betanzos  
Grupo LIDIA. CITIC.  
Universidade da Coruña  
A Coruña, España  
ciamparo@udc.es

Antonio Bahamonde  
Universidad de Oviedo  
Gijón, España  
abahamonde@uniovi.es

**Resumen**—Los algoritmos de selección de características son de gran importancia para manejar conjuntos de datos de grandes dimensiones. Sin embargo, algoritmos efectivos y populares como ReliefF tienen una complejidad computacional que impide su uso en estos casos. En este trabajo proponemos una modificación de ReliefF que se basa en la aproximación del grafo de vecinos más cercanos usando una adaptación del algoritmo VRLSH, basado en Hashing Sensible a la Localidad. El algoritmo resultante, llamado ReliefF-LSH, es capaz de procesar conjuntos de datos masivos que están fuera del alcance del original. Detallamos experimentos que atestiguan la validez del nuevo enfoque y demuestran su buena escalabilidad.

**Index Terms**—selección de características, escalabilidad, aprendizaje automático, Big Data

## I. INTRODUCCIÓN

La ciencia de datos está alcanzando gran relevancia gracias, en parte, a la enorme cantidad de datos que se generan diariamente en todos los ámbitos que constituyen lo que coloquialmente se conoce como *Big Data* [1]. No obstante, este aumento en el volumen de datos constituye un reto para los científicos de datos dado que los obliga a desarrollar nuevos algoritmos y a adaptar los existentes para que sean capaces de tratar grandes cantidades de datos y obtener información relevante en un tiempo razonable.

Existen numerosas técnicas para tratar con conjuntos de datos de alta dimensionalidad, entendiéndose por ello conjuntos con gran número de muestras o gran número de características para cada muestra. Cuando se dispone de muchas características para cada muestra es necesario aplicar técnicas de reducción de dimensionalidad. Entre las opciones del científico de datos están las técnicas de extracción de características, (que transforman un conjunto de características de entrada en un nuevo conjunto más pequeño en el cual cada característica es una función de varias características de entrada), o las técnicas de selección de características, que simplemente descartan las características redundantes o irrelevantes. A su vez, estas técnicas se pueden aplicar de manera explícita antes

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad (proyectos de investigación TIN 2015-65069-C2, tanto 1-R como 2-R y Red Española de Big Data y Análisis de datos escalable, TIN2016-82013-REDT), por la Xunta de Galicia (GRC2014/035 y ED431G/01) y por Fondos de Desarrollo Regional de la Unión Europea.

del entrenamiento como un paso de preprocesado de los datos, o se pueden realizar simultáneamente al aprendizaje.

Asimismo, para lidiar con el problema del volumen del *Big Data*, se han desarrollado plataformas de procesamiento distribuido que permiten utilizar hardware doméstico para formar clústeres de procesamiento que pueden analizar grandes cantidades de datos. La popularización de estas plataformas comenzó con el desarrollo del paradigma de programación MapReduce por Google en el año 2008 [2]. Desde entonces, han surgido varias implementaciones de código abierto que siguen ese paradigma, siendo Apache Hadoop [3] y, posteriormente, Apache Spark [4] las más populares. Su éxito dio lugar a la creación de librerías de aprendizaje automático como Mahout [5] para Hadoop y MLLib [6] para Spark y al desarrollo de versiones distribuidas de populares algoritmos, entre ellos algunos algoritmos de selección de características.

Además, en los casos en que la complejidad computacional del algoritmo no se puede reducir y el volumen de datos hace que incluso una implementación distribuida requiera un tiempo de ejecución muy alto para procesarlos, se puede recurrir a la utilización de técnicas que proporcionen aproximaciones a la solución exacta o más precisa (y también más costosa computacionalmente) pero que, dependiendo del problema, pueden obtener un rendimiento comparable.

En este trabajo hemos adaptado el popular algoritmo de selección de características ReliefF para reducir su complejidad computacional. Para ello, proponemos un cambio en el cálculo del grafo de vecinos más cercanos (construcción en la que se basa ReliefF) sustituyéndolo por un algoritmo de cálculo aproximado del grafo optimizado mediante el uso de Hashing Sensible a la Localidad. Esto, unido a la implementación del algoritmo resultante en Apache Spark que permite paralelizar gran parte de los cálculos, aumenta drásticamente su capacidad de procesar conjuntos grandes.

## II. TRABAJO RELACIONADO

El algoritmo Relief es un método de ordenación (ranking) de características atendiendo a su relevancia de cara a la clasificación [7]. Es un método supervisado, dado que requiere conocer la clase de cada ejemplo, y da como resultado una ordenación por importancia de las características, que posteriormente se puede utilizar para realizar una selección de

las mismas estableciendo un umbral de importancia a partir del cual se desechan las características que no lo alcancen. La idea principal es asignar un peso a cada atributo de acuerdo con su capacidad a la hora de distinguir ejemplos que se encuentran muy cerca. Por ello, para cada ejemplo, Relief busca el elemento de la misma clase (llamado *hit*) más cercano y el elemento de otra clase (llamado *miss*) más cercano y actualiza el peso de cada atributo  $A$  en función de la coincidencia o no de su valor en el ejemplo con el del *hit* y el del *miss*. El peso final  $W$  de cada atributo  $A$  tiene, por tanto, una interpretación probabilística ya que es una aproximación de la siguiente diferencia de probabilidades condicionadas:

$$W[A] = P(\text{valor diferente de } A | \text{miss más cercano}) - P(\text{valor diferente de } A | \text{hit más cercano}) \quad (1)$$

Su buen funcionamiento dio lugar a extensiones capaces de lidiar con problemas multiclase y ejemplos con ruido o incompletos [8]. ReliefF es una de estas extensiones y ha terminado siendo más popular que el algoritmo original, por lo que se ha implementado en numerosas librerías y software de aprendizaje automático. Posteriormente han sido publicadas especializaciones del algoritmo [9] para adaptarlo a problemas de regresión [10], multietiqueta [11], [12] o para tener en cuenta el coste de obtener cada atributo [13]. Además también se han hecho optimizaciones para facilitar su uso con grandes conjuntos de datos, basadas en implementaciones distribuidas [14], [15], muestreo [16] y en el uso de árboles  $k$ - $d$  aleatorios para aproximar el grafo de vecinos más cercanos [17], pero su aplicabilidad a conjuntos de alta dimensionalidad aún es limitada.

ReliefF, al igual que otros muchos métodos de selección de características, así como también problemas de Recuperación de Información, Minería de Datos y Aprendizaje Automático, se basa en el estudio de grafos de similitud entre elementos del conjunto de datos. Entre los grafos utilizados en aprendizaje máquina, el más popular es el grafo de los  $k$  vecinos más cercanos ( $kNN$  por sus siglas en inglés). Un grafo  $kNN$  es un grafo dirigido sobre  $n$  elementos,  $X = \vec{x}_1, \vec{x}_2, \dots, \vec{x}_n$ , en el que las aristas  $(\vec{x}_i, \vec{x}_j)$  indican que  $\vec{x}_j$  se encuentra entre los  $k$  elementos más similares a  $\vec{x}_i$  atendiendo a una medida de similitud  $S(\vec{x}_i, \vec{x}_j)$ . El grafo resultante es muy versátil, pero el coste computacional de su cálculo es muy alto, ya que requiere  $n(n-1)/2$  comparaciones, lo que sitúa su complejidad computacional en  $\mathcal{O}(n^2)$ . Se han propuesto algoritmos que calculan el grafo  $kNN$  exacto cuando la dimensionalidad del espacio de entrada es pequeña [18], además de algoritmos eficientes para medidas de similitud específicas [19], sin embargo, a la hora de lidiar con conjuntos de datos de alta dimensionalidad y medidas generales en tiempos manejables, solo se pueden construir soluciones aproximadas. Estas soluciones buscan replicar el grafo exacto con la mayor veracidad posible manteniendo el coste computacional bajo. Para obtener el grafo aproximado existen en la literatura algoritmos basados en diseño "divide y vencerás" [20], búsquedas locales [21] y en Hashing Sensible a la Localidad [22], [23].

En este sentido, el Hashing Sensible a la Localidad (LSH, por sus siglas en inglés) [24] es una técnica que se originó para construir estructuras de datos que permitiesen realizar consultas sobre un conjunto de datos en tiempo sublineal, aunque el método óptimo de explotar esta técnica todavía constituye un problema abierto. Básicamente, las técnicas de LSH permiten mapear datos de cualquier tamaño a un espacio, generalmente menor, utilizando una función de *hashing* que maximiza la probabilidad de que a datos similares se les asigne el mismo valor. Por este motivo, el uso de LSH para la construcción del  $kNN$  se ha explorado con éxito en la literatura [22], [23] con soluciones que utilizan LSH para aislar en pequeñas agrupaciones los elementos similares entre sí. A partir de estas agrupaciones se construyen subgrafos aislados que se combinan para obtener el grafo aproximado completo.

### III. ALGORITMO PROPUESTO

El propósito de este trabajo es obtener un algoritmo que aproxime el resultado de ReliefF con menor esfuerzo computacional. La mayor parte de la carga de trabajo de este algoritmo se invierte en el cómputo de los *hits* y *misses* más cercanos a cada dato, por lo tanto, es esta parte del algoritmo la que se propone sustituir por el algoritmo LSH de Radio Variable (VRLSH, de sus siglas en inglés) [23]. Este algoritmo utiliza proyecciones LSH iterativas para obtener el grafo  $kNN$  aproximado, como se explica a continuación.

En primer lugar, se asignan una o varias claves *hash* a cada elemento  $\vec{x}_i$  del conjunto de datos  $X$  usando una función LSH. Esta función está diseñada para asignar claves iguales a elementos similares de acuerdo a una medida de similitud dada y usando un nivel de resolución o *radio* de búsqueda también dado, que inicialmente será pequeño para buscar similitudes muy exactas. A continuación, se agrupan los elementos a los que se les ha asignado la misma clave. Tendremos, gracias a las propiedades de la función *hash*, pequeños grupos o "cúmulos" de elementos similares de acuerdo a la medida de similitud dada. A partir de estas agrupaciones para cada una de ellas se computa un subgrafo  $kNN$  exacto por el método de fuerza bruta, consistente en comparar cada elemento con todos los demás de su mismo cúmulo. Dado que un mismo elemento  $\vec{x}_i$  puede pertenecer a varios cúmulos, posteriormente y si existe este solapamiento, los subgrafos de los cúmulos implicados se fusionan para incluir todos los vecinos que han sido detectados para  $\vec{x}_i$ . A continuación, se simplificará el conjunto de datos  $X$  eliminando aquellos elementos  $\vec{x}_i$  que hayan estado involucrados en al menos un número preestablecido  $C_{MAX} > k$  de comparaciones. Este proceso se repetirá, utilizando el nuevo  $X$ , para generar nuevos subgrafos que se fusionarán entre sí y con los ya existentes, hasta que el grafo fusionado contenga todos los elementos del conjunto original. En cada nueva iteración se aumentará la resolución, lo cual permitirá agrupar elementos un poco más diferentes que en la iteración anterior. Finalmente, si algún elemento queda con menos de  $k$  vecinos, se completará con los vecinos de sus vecinos o con los vecinos de elementos al azar si no tuviese ninguno. Este proceso aparece descrito en el Algoritmo 2.



Adicionalmente, para que este grafo resulte de utilidad a ReliefF en el cálculo de los pesos  $W$  de cada atributo es necesario hacer una modificación de VRLSH. El algoritmo VRLSH mantiene una única lista de vecinos para cada elemento del conjunto de datos. ReliefF, sin embargo, necesita distinguir *hits* y los *misses* más cercanos de cada clase, por lo que es necesario adaptar VRLSH para que mantenga una lista de vecinos por cada posible clase para cada elemento del conjunto de datos.

**Entrada:**  $X \leftarrow$  Conjunto de datos  
 $k \leftarrow$  Número de vecinos a obtener  
 $R_{INI} \leftarrow$  Radio de búsqueda inicial  
 $C_{MAX} \leftarrow$  Máximas comparaciones por elemento  
 $N \leftarrow$  Número de hashes a obtener  
 $L \leftarrow$  Longitud de cada hash  
**Salida:**  $G \leftarrow$  Grafo kNN

```

1  $G \leftarrow \emptyset$ ,  $cúmulos \leftarrow \emptyset$ ,  $originalX \leftarrow X$ ,
   $radio \leftarrow R_{INI}$ 
2 mientras  $|cúmulos| > 1$  or  $|X| > 1$  and  $|X| < k$  hacer
3    $hashElems \leftarrow LSH(X, radio, N, L)$ 
4    $cúmulos \leftarrow hashElems.agrupaPorHash()$ 
5   para cada  $c$  in  $cúmulos$  hacer
6     si  $|c| > 1$  entonces
7        $G \leftarrow G \cup KNN_{exacto}(c.elems, k)$  fin
8     fin
9    $X \leftarrow X -$ 
10     $G.nodosConAlMenosNComparaciones(C_{MAX})$ 
11     $radio \leftarrow radio * 2$ 
12 fin
13 si  $|X| > 1$  entonces
14   para cada  $x$  in  $X$  hacer
15     si  $|x.vecinos| = 0$  entonces
16        $x.vecinos \leftarrow alAzar(originalX, k)$ 
17     en otro caso
18        $x.vecinos \leftarrow$ 
19         $x.vecinos \cup desciendeVecinos(X, G)$ 
20     fin
21  $G \leftarrow G \cup desciendeVecinos(X, G)$ 
22 fin

```

**Algoritmo 1:** Pseudocódigo del algoritmo VRLSH

#### IV. EXPERIMENTACIÓN

Para comprobar la validez del método propuesto se han llevado a cabo dos baterías de experimentos. En primer lugar se ha medido el tiempo de ejecución necesario para el cómputo de los pesos de los atributos usando ReliefF en conjuntos de datos reales y se ha comparado con el tiempo que requiere ReliefF-LSH sobre los mismos conjuntos. Dado que ReliefF-LSH es un método aproximado, se ha medido además la exactitud de los resultados obtenidos comparando las ordenaciones de atributos obtenidas por los dos métodos. La segunda batería de experimentos va encaminada a comprobar la escalabilidad

**Entrada:**  $X \leftarrow$  Conjunto de datos  
 $k \leftarrow$  Número de vecinos a utilizar  
**Salida:**  $W \leftarrow$  Vector de pesos asignados a cada atributo

```

1 para cada  $A$  in  $X.atributos$  hacer
2    $W[A] \leftarrow 0$ 
3 fin
4  $G \leftarrow VRLSH(X, k, R_{INI}, C_{MAX}, N, L)$ 
5 para cada  $x \in X$  in  $G$  hacer
6   para cada  $A$  in  $X.atributos$  hacer
7      $c \leftarrow x.clase$ 
8      $W[A] \leftarrow W[A] - \sum_{j=1}^k \frac{diff(A, x, vecinos(c)_j)}{|X| * k} +$ 
9        $\sum_{\gamma \neq c} \left[ \frac{P(c)}{1 - P(\gamma)} \sum_{j=1}^k \frac{diff(A, x, vecinos(\gamma)_j)}{|X| * k} \right]$ 
10    fin
11 fin

```

**Algoritmo 2:** Pseudocódigo de ReliefF-LSH

del método. Para ello se compara el tiempo de ejecución de ReliefF-LSH sobre los mismos conjuntos reales utilizando un número creciente de núcleos de cómputo.

#### IV-A. Datos y metodología

Todos los experimentos se llevaron a cabo en máquinas con 12 núcleos de computación que forman parte de un clúster. La descripción de cada nodo de computación aparece en el Cuadro I. La versión de Spark utilizada es la 1.6.1, sobre Hadoop 2.7.1.2.4.2.0-258. El sistema operativo instalado en las máquinas es CentOS Linux release 7.4.1708.

Cuadro I  
DESCRIPCIÓN DEL CLÚSTER DE COMPUTACIÓN

32 nodos con las siguientes características:	
<b>Procesador:</b>	2 × Intel Xeon E5-2620 v3 a 2.40Ghz
<b>Núcleos:</b>	6 por procesador (12 por nodo)
<b>Threads:</b>	2 por núcleo (24 en total por nodo)
<b>Disco:</b>	12 × 2TB NL SATA 6Gbps 3.5" G2HS
<b>RAM:</b>	64 GB
<b>Red:</b>	1x10Gbps + 2x1Gbps

Para realizar estos experimentos se eligieron cuatro conjuntos de datos reales de alta dimensionalidad. En primer lugar se utilizó *Higgs*, que representa propiedades cinéticas de partículas detectadas en un acelerador<sup>1</sup> [25]. Consta de 28 atributos numéricos y 11 millones de ejemplos. En segundo lugar se usó el conjunto artificial *Epsilon*, creado para el Pascal Large Scale Learning Challenge [26] en 2008 y que se compone de 500.000 ejemplos con 2.000 atributos cada uno. Por último, se utilizó el conjunto multiclase *Isolet* [27], que tiene 7.900 ejemplos de 617 atributos distribuidos en 27 clases. Los conjuntos utilizados y sus características aparecen reflejados en el Cuadro II.

<sup>1</sup>Disponible para descarga en <https://archive.ics.uci.edu/ml/datasets/HIGGS>

Cuadro II  
DESCRIPCIÓN DE LOS CONJUNTOS DE DATOS

Conjunto	Atributos	Muestras	Clases
Higgs	28	11.000.000	2
Epsilon	2.000	500.000	2
Isolet	617	7.900	27

Cuadro III  
TIEMPO DE EJECUCIÓN DE LAS IMPLEMENTACIONES

	Tiempo (s)	
	ReliefF	ReliefF-LSH
# núcleos	12	12
Higgs (0.5 %)	5.550	32
Epsilon (10 %)	13.150	2.264
Isolet	320	29

El alto número de muestras de algunos conjuntos los sitúa fuera del alcance de la versión original de ReliefF, dado que su tiempo de ejecución sería de semanas, aún utilizando 12 núcleos de computación. En consecuencia, para el primer experimento consistente en comparar los tiempos de ejecución de la versión original con ReliefF-LSH se usaron versiones reducidas de los conjuntos más grandes tomando solamente los  $N$  primeros elementos del conjunto. En particular, se tomó el primer 0.5 % de los datos del conjunto Higgs (55.000 elementos) y el primer 10 % de Epsilon (50.000 elementos). No obstante, para demostrar la capacidad del método para tratar con conjuntos grandes, en el segundo experimento se utilizaron las versiones completas de los conjuntos.

#### IV-B. Resultados

El primer experimento consistió en comparar los resultados obtenidos con ReliefF-LSH con los obtenidos por la versión exacta. En primer lugar se compararon los tiempos de ejecución necesarios para procesar cada conjunto de datos, mostrados en el Cuadro III. Se puede apreciar que los tiempos de ejecución de ReliefF-LSH son siempre muy inferiores a los de su contrapartida exacta. Cabe destacar que, tal como se describe en [23], tanto el tiempo de ejecución de VRLSH como su precisión dependen de los hiperparámetros con que se ejecute. En este caso los hiperparámetros fueron obtenidos empíricamente para que el grafo aproximado se computase realizando en torno al 1 % de las comparaciones necesarias para calcular el grafo exacto. No obstante, existe un equilibrio entre tiempo de cómputo y exactitud del grafo obtenido que el usuario debe manejar en función de sus preferencias. Los hiperparámetros utilizados para este experimento aparecen listados en el Cuadro V.

En lo referente a la exactitud de los subconjuntos de características seleccionadas por ReliefF-LSH, estas dependen en gran medida de dos factores. En primer lugar, si ReliefF asigna a las características de un conjunto puntuaciones que difieren muy poco, es probable que el cálculo aproximado obtenga valores ligeramente distintos que las ordenen de manera distinta. Por contra, los conjuntos que muestran

grandes diferencias entre sus características en términos de la puntuación otorgada por ReliefF, obtienen rankings más robustos frente a las pequeñas diferencias de puntuación derivadas del cálculo aproximado. En segundo lugar, la exactitud de las puntuaciones otorgadas por Relief-LSH dependen de la exactitud del grafo aproximado calculado con VRLSH y que, como ya se mencionó anteriormente, viene determinado por el número de comparaciones entre pares que se hayan realizado, que a su vez se determinan en función de los hiperparámetros utilizados. Para representar la exactitud de los subconjuntos de características obtenidos hemos definido el ratio de coincidencia entre el subconjunto seleccionado por el algoritmo exacto ( $\mathcal{E}$ ) y el seleccionado por ReliefF-LSH ( $\mathcal{L}$ ) definido como:

$$R = \frac{|\mathcal{E} \cap \mathcal{L}|}{\mathcal{E}} \quad (2)$$

En la Figura 1 hemos representado el ratio de coincidencia para distintos niveles de selección dentro del ranking devuelto por los algoritmos. La ordenación de características para el conjunto de datos *Higgs* se realizó sobre un grafo aproximado calculado con alrededor de  $5 * 10^{-3}$  veces menos cálculos de los que requeriría el grafo exacto. Esto se tradujo en un tiempo de ejecución muy bajo, pero también el nivel de coincidencia es bajo cuando se seleccionan pocos atributos. Por el contrario, los niveles de coincidencia para los atributos seleccionados en el caso de los conjuntos *Epsilon* y *Isolet* son más altos, rondando el 90 % en el caso de *Epsilon* y el 80 % en *Isolet*. Es importante destacar, no obstante, que para niveles de selección muy extremos en los que nos quedamos con muy pocas variables es posible que los pequeños cambios en la ordenación de variables dejen fuera algunas que sí aparecen en la selección exacta, disminuyendo así el ratio de coincidencia.

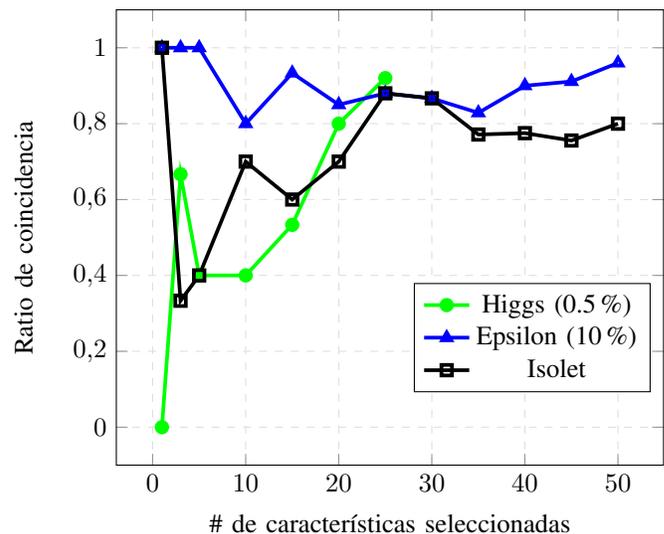


Figura 1. Ratio de coincidencia de las características seleccionadas por ReliefF vs ReliefF-LSH para los conjuntos Higgs (0.5%), Epsilon (10%) y Isolet.

Finalmente, realizamos un experimento con el objetivo de estudiar la escalabilidad del método. Para ello tomamos las



Cuadro IV  
TIEMPO DE EJECUCIÓN DE RELIEF-LSH. ESCALABILIDAD

	Tiempo (s)		
	ReliefF-LSH		
# núcleos	12	2x12	4x12
Higgs	15.726	4.206	2.580
Isolet	29	30	31

versiones completas del conjunto con más muestras (*Higgs*) y con menos muestras (*Isolet*) y realizamos el cómputo del ranking de atributos repetidas veces, utilizando en cada una distinto número de nodos de computación. Los tiempos invertidos en cada caso aparecen reflejados en el Cuadro IV.

Este experimento pone de relieve la capacidad de ReliefF-LSH de procesar conjuntos que están completamente fuera del alcance de la versión exacta de ReliefF. Así, mientras que la versión exacta invirtió 5.550 segundos en procesar el 0.5 % de los ejemplos de *Higgs*, ReliefF-LSH pudo realizar el cómputo con el conjunto completo (200 veces mayor) en 15.726 segundos. Cabe recordar que, al ser la complejidad del ReliefF original de orden cuadrático en el número de muestras, cabría esperar un tiempo de ejecución del orden de  $10^7$  segundos, lo cual es inabarcable en la práctica. Además, se puede apreciar en los resultados que, gracias a que gran parte de los cálculos se pueden realizar independientemente de manera paralela, los nodos de cómputo que se añaden son aprovechados cuando el conjunto es grande, lo que se traduce en una relación inversamente proporcional de pendiente cercana a -1 entre el número de nodos de cómputo y el tiempo de ejecución, como es deseable. Esto no es así en conjuntos pequeños como *Isolet*, dado que el número de operaciones requeridas es bajo y la aceleración derivada de la paralelización se ve compensada por el sobreesfuerzo de comunicación que implica la distribución del trabajo a los nodos de cómputo.

Por otra parte, hay que recordar que ReliefF-LSH utiliza proyecciones aleatorias a la hora de computar el grafo de vecinos más cercanos, lo cual introduce un factor de azar que hace que cada ejecución sea distinta incluso cuando utilice los mismos hiperparámetros. Esto provoca que los tiempos de cómputo puedan variar entre ejecuciones. Finalmente, también en este apartado entra en juego el balance entre exactitud y rapidez mencionado anteriormente. Los valores de los hiperparámetros utilizados aparecen reflejados en el Cuadro V. Se puede comprobar que en el caso del conjunto de datos *Higgs* se realizaron  $3,5 \times 10^{-6}$  veces menos operaciones de las que se necesitarían para calcular el grafo exacto. Es posible que esto diese como resultado una ordenación de las características con un bajo ratio de coincidencia con el eventual resultado exacto - que resulta impracticable calcular. Dependiendo del nivel de selección deseado y del rendimiento de la selección realizada en el problema posterior para el que se precise, el usuario podría decidir obtener una ordenación más coincidente con la eventual solución exacta. Por suerte, gracias a la escalabilidad del método, el cálculo de un grafo más exacto alterando los hiperparámetros se puede realizar en un tiempo similar al

Cuadro V  
DESCRIPCIÓN DE LOS HIPERPARÁMETROS DE VRLSH UTILIZADOS.  
*Operaciones* INDICA LA FRACCIÓN DE OPERACIONES REALIZADAS CON RESPECTO AL CÁLCULO EXACTO.

Conjunto	L	N	R	Operaciones
Higgs (0.5 %)	5	20	0.5	$4,6 \times 10^{-3}$
Higgs	8	5	0.25	$3,5 \times 10^{-6}$
Epsilon (10 %)	70	5	0.25	$3,7 \times 10^{-2}$
Isolet	5	4	0.1	$2,8 \times 10^{-3}$

registrado con tan solo añadir más nodos al cómputo.

## V. CONCLUSIONES

En este trabajo se ha propuesto una adaptación del popular algoritmo de selección de características ReliefF para posibilitar el tratamiento de grandes volúmenes de datos. Se ha hecho uso del algoritmo VRLSH para aproximar el cálculo de vecinos más cercanos, que constituye la parte más costosa computacionalmente de ReliefF, y se obtiene así una ordenación aproximada de las características del conjunto de datos. El algoritmo resultante, llamado ReliefF-LSH, se ha implementado en la plataforma Apache Spark y se han realizado experimentos para verificar la validez del método y su escalabilidad. Los experimentos muestran que ReliefF-LSH es un algoritmo que puede tratar conjuntos que están muy fuera del alcance de ReliefF. Asimismo, el algoritmo propuesto ofrece al usuario la posibilidad de balancear la rapidez de ejecución con la exactitud de la solución, lo que lo convierte en una versátil herramienta para problemas de distintas complejidades.

Actualmente estamos trabajando en simplificar el manejo de los hiperparámetros de VRLSH por parte del usuario, para facilitar el mencionado balanceo de rapidez y precisión. Igualmente, como trabajo futuro queremos añadir estructuras de datos que eviten cómputos duplicados, acelerando la ejecución.

## AGRADECIMIENTOS

Los autores desean agradecer a la Fundación Pública Galega Centro Tecnológico de Supercomputación de Galicia (CES-GA) el uso de sus recursos de computación.

## REFERENCIAS

- [1] Saint John Walker. Big data: A revolution that will transform how we live, work, and think, 2014.
- [2] Jeffrey Dean and Sanjay Ghemawat. Mapreduce: simplified data processing on large clusters. *Communications of the ACM*, 51(1):107–113, 2008.
- [3] Apache Hadoop Project. <http://hadoop.apache.org/>. Accessed: 2016-04-19.
- [4] Matei Zaharia, Mosharaf Chowdhury, Michael J Franklin, Scott Shenker, and Ion Stoica. Spark: Cluster computing with working sets. *HotCloud*, 10(10-10):95, 2010.
- [5] Apache Mahout Project. <http://mahout.apache.org/>. Accessed: 2016-04-19.
- [6] Xiangrui Meng, Joseph Bradley, Burak Yavuz, Evan Sparks, Shivaram Venkataraman, Davies Liu, Jeremy Freeman, DB Tsai, Manish Amde, Sean Owen, et al. Mllib: Machine learning in apache spark. *The Journal of Machine Learning Research*, 17(1):1235–1241, 2016.
- [7] Kenji Kira and Larry A Rendell. A practical approach to feature selection. In *Machine Learning Proceedings 1992*, pages 249–256. Elsevier, 1992.

- [8] Igor Kononenko. Estimating attributes: analysis and extensions of relief. In *European conference on machine learning*, pages 171–182. Springer, 1994.
- [9] Ryan J Urbanowicz, Melissa Meeker, William LaCava, Randal S Olson, and Jason H Moore. Relief-based feature selection: introduction and review. *arXiv preprint arXiv:1711.08421*, 2017.
- [10] Marko Robnik-Šikonja and Igor Kononenko. An adaptation of relief for attribute estimation in regression. In *Machine Learning: Proceedings of the Fourteenth International Conference (ICML'97)*, pages 296–304, 1997.
- [11] Newton Spolaôr, Everton Alvares Cherman, Maria Carolina Monard, and Huei Diana Lee. Relieff for multi-label feature selection. In *Intelligent Systems (BRACIS), 2013 Brazilian Conference on*, pages 6–11. IEEE, 2013.
- [12] Ivica Slavkov, Jana Karcheska, Dragi Koccev, Slobodan Kalajdziski, and Sašo Džeroski. Relieff for hierarchical multi-label classification. In *International Workshop on New Frontiers in Mining Complex Patterns*, pages 148–161. Springer, 2013.
- [13] Verónica Bolón-Canedo, Beatriz Remeseiro, Noelia Sánchez-Marño, and Amparo Alonso-Betanzos. mc-relieff-an extension of relief for cost-based feature selection. In *ICAART (1)*, pages 42–51, 2014.
- [14] Carlos Eiras-Franco, Verónica Bolón-Canedo, Sabela Ramos, Jorge González-Domínguez, Amparo Alonso-Betanzos, and Juan Touriño. Multithreaded and spark parallelization of feature selection filters. *Journal of Computational Science*, 17:609–619, 2016.
- [15] Raul-Jose Palma-Mendoza, Daniel Rodriguez, and Luis de Marcos. Distributed relieff-based feature selection in spark. *Knowledge and Information Systems*, pages 1–20, 2018.
- [16] Margaret J Eppstein and Paul Haake. Very large scale relieff for genome-wide association analysis. In *Computational Intelligence in Bioinformatics and Computational Biology, 2008. CIBCB'08. IEEE Symposium on*, pages 112–119. IEEE, 2008.
- [17] Sitong Xu, Xiang Li, and Wen Feng Lu. Randomized kd tree relieff algorithm for feature selection in handling high dimensional process parameter data. In *Emerging Technologies and Factory Automation (ETFA), 2016 IEEE 21st International Conference on*, pages 1–8. IEEE, 2016.
- [18] Jon Louis Bentley. Multidimensional binary search trees used for associative searching. *Communications of the ACM*, 18(9):509–517, 1975.
- [19] David C Anastasiu and George Karypis. L2knn: Fast exact k-nearest neighbor graph construction with l2-norm pruning. In *Proceedings of the 24th ACM International on Conference on Information and Knowledge Management*, pages 791–800. ACM, 2015.
- [20] Jie Chen, Haw-ren Fang, and Yousef Saad. Fast approximate knn graph construction for high dimensional data via recursive lanczos bisection. *Journal of Machine Learning Research*, 10(Sep):1989–2012, 2009.
- [21] Wei Dong, Charikar Moses, and Kai Li. Efficient k-nearest neighbor graph construction for generic similarity measures. In *Proceedings of the 20th international conference on World wide web*, pages 577–586. ACM, 2011.
- [22] Yan-Ming Zhang, Kaizhu Huang, Guanggang Geng, and Cheng-Lin Liu. Fast knn graph construction with locality sensitive hashing. In *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, pages 660–674. Springer, 2013.
- [23] Carlos Eiras-Franco, Leslie Kanthan, Amparo Alonso-Betanzos, and David Martinez-Rego. Scalable approximate k-nn graph construction based on locality sensitive hashing.
- [24] Alexandr Andoni and Piotr Indyk. Near-optimal hashing algorithms for approximate nearest neighbor in high dimensions. In *Foundations of Computer Science, 2006. FOCS'06. 47th Annual IEEE Symposium on*, pages 459–468. IEEE, 2006.
- [25] Pierre Baldi, Peter Sadowski, and Daniel Whiteson. Searching for exotic particles in high-energy physics with deep learning. *Nature communications*, 5:4308, 2014.
- [26] Soeren Sonnenburg, Vojtech Franc, Elad Yom-Tov, and Michele Sebag. Pascal large scale learning challenge. In *25th International Conference on Machine Learning (ICML2008) Workshop*. <http://largescale.first.fraunhofer.de>. *J. Mach. Learn. Res.*, volume 10, pages 1937–1953, 2008.
- [27] Dua Dheeru and Efi Karra Taniskidou. UCI machine learning repository, 2017.

# **II Workshop en Big Data y Análisis de Datos Escalable (II BigDADE)**

SESIÓN 2







# Smart Data: Filtrado de Ruido para Big Data

Diego García-Gil\*, Julián Luengo\*, Salvador García\* y Francisco Herrera\*

\*Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad de Granada, Granada, España, 18071

Email: {djgarcia,julianlm,salvagl,herrera}@decsai.ugr.es

**Resumen**—En cualquier proceso de minería de datos, el valor del conocimiento extraído está directamente relacionado con la calidad de los datos utilizados. Los problemas Big Data, generados por el crecimiento masivo de los datos en los últimos años, siguen el mismo dictado. Un problema común que afecta a la calidad de los datos es la presencia de ruido, especialmente en los problemas de clasificación, en los que el ruido de clase se refiere al etiquetado incorrecto de las instancias de entrenamiento. Sin embargo, en la era del Big Data, las grandes cantidades de datos plantean un reto a las propuestas tradicionales creadas para hacer frente al ruido, ya que tienen dificultades para procesar tal cantidad de datos. Es necesario proponer nuevos algoritmos para el tratamiento de ruido en Big Data, obteniendo datos limpios y de calidad, también conocidos como Smart Data. En este trabajo se proponen dos enfoques de preprocesamiento de datos en Big Data para eliminar instancias ruidosas: un ensemble homogéneo y un ensemble heterogéneo, con especial énfasis en su escalabilidad y rendimiento. Los resultados obtenidos muestran que estas propuestas permiten obtener eficientemente un Smart Dataset a partir de cualquier problema de clasificación Big Data.

**Index Terms**—Big Data, Smart Data, Clasificación, Preprocesamiento, Ruido de clase

## I. PRELIMINARES

Hoy en día estamos rodeados por enormes cantidades de datos. Está previsto que para 2020 el universo digital sea 10 veces más grande que en 2013, totalizando unos asombrosos 44 zettabytes <sup>1</sup>. El volumen actual de datos ha superado las capacidades de procesamiento de los sistemas clásicos de minería de datos y ha creado la necesidad de nuevos frameworks para almacenarlos y procesarlos. Es un hecho ampliamente aceptado que hemos entrado en la era del Big Data. El Big Data es el conjunto de tecnologías que hacen posible el procesamiento de grandes cantidades de datos.

En Big Data, las técnicas preprocesamiento clásicas para mejorar la calidad de los datos consumen aún más tiempo y exigen más recursos, volviéndose inviables. La falta de técnicas de preprocesamiento eficientes y asequibles implica que las alteraciones en los datos afectarán a los modelos extraídos de ellos. Entre todos los problemas que pueden aparecer en los datos, la presencia de *ruido* es uno de los más frecuentes. El ruido puede definirse como la alteración parcial o total de la información recogida en una instancia causada por un factor externo. El ruido conduce a modelos excesivamente complejos con un rendimiento degradado.

Recientemente, se ha introducido el concepto Smart Data (centrado en la veracidad y el valor de los datos), con el objetivo de filtrar el ruido y resaltar los datos valiosos. Hay

tres atributos clave para que los datos sean *inteligentes*, deben ser:

- Precisos: los datos deben ser lo que dicen que son con suficiente precisión para generar valor. La calidad de los datos es importante.
- Procesables: los datos deben ser escalables inmediatamente para maximizar objetivos empresariales.
- Rápidos: los datos deben estar disponibles en tiempo real y listos para adaptarse a las cambiantes exigencias empresariales.

El modelado y análisis avanzado en Big Data es indispensable para descubrir la estructura subyacente en los datos con el fin de obtener Smart Data. En este trabajo aportamos varias técnicas de preprocesamiento para Big Data, transformando conjuntos de datos sin procesar en Smart Data. Nos hemos centrado en la tarea de clasificación, donde se distinguen dos tipos de ruido: *ruido de clase*, cuando afecta a la etiqueta de una instancia, y *ruido de atributo*, cuando afecta a los atributos. El primero es conocido por ser el más perjudicial [1]. Como consecuencia, muchos trabajos, incluido este, han sido dedicados a resolver este problema, o al menos a minimizar sus efectos (en [2] encontramos una completa revisión).

A pesar de que se han propuesto algunos diseños para tratar el ruido en Big Data [3], no se ha propuesto ningún algoritmo para eliminar el ruido ni se ha llevado a cabo ninguna comparación en Big Data.

Por esto proponemos un framework para eliminar instancias ruidosas en Big Data sobre Apache Spark, compuesto de dos algoritmos basados en ensembles de clasificadores. El primero es un Ensemble Homogéneo (EHO), el cual usa un clasificador base (Random Forest [4]) sobre un dataset particionado. El segundo es un Ensemble Heterogéneo (EHT), el cual usa tres clasificadores para identificar instancias ruidosas: Random Forest, Regresión Logística y k-Nearest Neighbors (kNN). Para una comparativa más completa, hemos implementado un filtro basado en similaridad de instancias, llamado Edited Nearest Neighbor (ENN). ENN examina los vecinos más cercanos de cada ejemplo de entrenamiento y elimina aquellos cuyo vecindario pertenece a una clase diferente. Todas estas técnicas han sido implementadas en Apache Spark [5], y pueden ser descargadas de su repositorio comunitario <sup>2</sup>.

Para mostrar el rendimiento de los métodos propuestos, hemos llevado a cabo experimentos con cuatro grandes datasets: *SUSY*, *HIGGS*, *Epsilon* y *ECBDL14*. Hemos creado diferentes niveles de ruido de clase para evaluar los efectos de aplicar los

<sup>1</sup>IDC: The Digital Universe of Opportunities. 2018 [Online] <http://www.emc.com/infographics/digital-universe-2014.htm>

<sup>2</sup><https://spark-packages.org/package/djgarcia/NoiseFramework>

métodos, así como la mejora obtenida en términos de precisión para dos clasificadores: un árbol de decisión y kNN. También mostramos que, en los problemas estudiados, los clasificadores se benefician del filtrado de ruido incluso cuando no hay ruido añadido, ya que los problemas Big Data contienen ruido propio debido a la automatización en la recogida de los datos. Los resultados indican que la propuesta es capaz de eliminar exitosamente el ruido. En concreto, EHO es la primera técnica válida para tratar el ruido en problemas Big Data, mejorando la precisión con un bajo coste computacional.

El resto del trabajo está organizado como sigue: la Sección II explica el framework propuesto. La Sección III describe los experimentos llevados a cabo para probar el rendimiento del framework. Finalmente, la Sección IV concluye el trabajo.

## II. FILTRADO DE RUIDO EN BIG DATA

En esta sección, presentamos el primer framework para Big Data sobre Apache Spark para eliminar instancias ruidosas basado en el modelo MapReduce. Se trata de un diseño MapReduce donde todos los procesos de filtrado de ruido se realizan de forma distribuida. En la Sección II-A describimos el modelo MapReduce. En la Sección II-B listamos las primitivas de Spark usadas en la implementación del framework. Hemos diseñado dos algoritmos basados en ensembles. Ambos realizan un  $k$ -fold a los datos de entrada, aprenden un modelo en cada partición de entrenamiento y limpian las instancias ruidosas de la partición de test. El primero es un ensemble homogéneo que utiliza Random Forest como clasificador, llamado EHO (Sección II-C). El segundo, llamado EHT (Sección II-D), es un ensemble heterogéneo basado en tres clasificadores: Random Forest, Regresión Logística y kNN.

### II-A. Modelo MapReduce

MapReduce es un framework diseñado por Google en 2003 [6], [7]. Este modelo se compone de una función Map, que realiza una transformación, y un método Reduce, que realiza una agregación. El flujo de trabajo de una tarea MapReduce es el siguiente: el nodo máster divide el conjunto de datos y lo distribuye por el clúster. Después cada nodo aplica la función Map a sus datos. A continuación, los datos se redistribuyen por el clúster en función de los pares clave-valor generados en la fase Map. Una vez que todos los pares de una misma clave están en el mismo nodo, se procesan en paralelo.

Apache Hadoop<sup>3</sup> es el framework open-source más conocido para el almacenamiento y procesamiento de grandes cantidades de datos, basado en el modelo MapReduce. El framework está diseñado para tratar los errores de hardware automáticamente. A pesar de su popularidad y rendimiento, Hadoop tiene algunas limitaciones [8]: bajo rendimiento para tareas iterativas e imposibilidad de trabajar en memoria.

Apache Spark<sup>4</sup> es un framework open-source centrado en la velocidad, facilidad de uso y procesamiento en memoria [9]. Spark está construido sobre una estructura de datos distribuida

e inmutable llamada Resilient Distributed Datasets (RDDs) [10]. Los RDDs se pueden describir como un conjunto de particiones de datos distribuidas por el clúster. Los RDDs soportan dos tipos de operaciones: acciones, que evalúan y devuelven un valor. Y transformaciones, que no son evaluadas cuando se definen, se aplican sobre un RDD y producen un nuevo RDD. Cuando se llama a una acción sobre un RDD, todas las transformaciones previas se aplican en paralelo a cada partición del RDD.

### II-B. Primitivas Spark

Para la implementación del framework, hemos utilizado algunas primitivas de la API de Spark. Estas funciones ofrecen operaciones más complejas al extender el modelo MapReduce. A continuación, describimos las empleadas en los algoritmos:

- *map*: Aplica una transformación a cada elemento de un RDD.
- *zipWithIndex*: Para cada elemento de un RDD crea una tupla con el elemento y su índice, empezando en 0.
- *join*: Devuelve un RDD que contiene todos los pares de elementos cuyas claves coinciden entre dos RDDs.
- *filter*: Devuelve un nuevo RDD que contiene solo los elementos que satisfacen una condición.
- *union*: Devuelve un RDD resultante de la unión de dos RDDs.
- *kFold*: Devuelve una lista de  $k$  pares de RDDs, siendo el primer elemento los datos de *train*, y el segundo elemento los datos de *test*. Donde  $k$  es el número de particiones.
- *randomForest*: Método para aprender un modelo de Random Forest.
- *predict*: Devuelve un RDD que contiene las instancias y clases predichas para un dataset usando un modelo.
- *learnClassifiers*: A pesar de no ser una primitiva de Spark, la usamos para simplificar la descripción de los algoritmos. Esta primitiva aprende un modelo de Random Forest, Regresión Logística y INN a partir de los datos de entrada.

Estas primitivas de Spark se usan en las siguientes secciones donde describimos EHO y EHT.

### II-C. Ensemble Homogéneo: EHO

El ensemble homogéneo está inspirado en Cross-Validated Committees Filter (CVCF) [11]. Este filtro elimina instancias ruidosas realizando un  $k$ -fold a los datos. Después entrena un árbol de decisión  $k$  veces, dejando fuera uno de los subconjuntos cada vez. Esto da como resultado  $k$  clasificadores que se utilizan para predecir los datos de entrenamiento  $k$  veces. Luego, utilizando una estrategia de voto, se eliminan las instancias mal clasificadas.

EHO también está basado en un esquema de particionamiento de los datos. Hay una diferencia importante con respecto a CVCF: el uso de Random Forest en lugar de un árbol de decisión como clasificador. CVCF crea un ensemble particionando los datos de entrenamiento. EHO también divide

<sup>3</sup>Apache Hadoop Project 2018 [Online] <https://hadoop.apache.org/>

<sup>4</sup>Apache Spark Project 2018 [Online] <https://spark.apache.org/>



Figura 1. Algoritmo EHO

```

1: Entrada: data RDD de tuplas (clase, atributos)
2: Entrada: P número de particiones
3: Entrada: nTrees número de árboles para Random Forest
4: Salida: RDD filtrado sin ruido
5: partitions  $\leftarrow kFold(data, P)$ 
6: filteredData  $\leftarrow \emptyset$ 
7: for all train, test in partitions do
8:   rfModel  $\leftarrow randomForest(train, nTrees)$ 
9:   rfPred  $\leftarrow predict(rfModel, test)$ 
10:  joinedData  $\leftarrow join(zipWithIndex(test), zipWithIndex(rfPred))$ 
11:  markedData  $\leftarrow$ 
12:    map original, prediction  $\in$  joinedData
13:      if label(original) = label(prediction) then
14:        original
15:      else
16:        (label =  $\emptyset$ , features(original))
17:      end if
18:    end map
19:  filteredData  $\leftarrow union(filteredData, markedData)$ 
20: end for
21: return (filter(filteredData, label  $\neq \emptyset$ ))

```

los datos de entrenamiento, pero el uso de Random Forest nos permite mejorar el paso de la votación:

- CVCF predice el dataset entero  $k$  veces. EHO solo predice las instancias de la partición *test* del  $k$ -fold. Este paso se repite  $k$  veces. Con este cambio no solo mejoramos el rendimiento, sino también el tiempo de cómputo, ya que solo tiene que predecir una pequeña parte de los datos de entrenamiento en cada iteración.
- No necesitamos implementar una estrategia de votación, la decisión de si una instancia es ruidosa está asociada con la predicción del Random Forest.

La Figura 1 describe el proceso de filtrado de ruido en EHO. Los parámetros de entrada son los siguientes: el dataset (*data*), el número de particiones ( $P$ ) y el número de árboles para el Random Forest (*nTrees*):

- El algoritmo realiza un  $kFold$  en los datos de entrada. Como se definió antes, la función  $kFold$  de Spark devuelve una lista de (*train, test*) para un  $P$  dado.
- Iteramos sobre cada partición, aprendiendo un Random Forest usando *train* como datos de entrada, y prediciendo *test* usando el modelo aprendido.
- Para unir los datos de *test* y los datos predichos para comparar las clases, usamos la operación  $zipWithIndex$  en ambos RDDs. Con esta operación, añadimos un índice a cada elemento de ambos RDDs. Este índice se utiliza como clave para la operación  $join$ .
- El siguiente paso es aplicar una función  $map$  al RDD anterior y comprobar, para cada instancia, la clase original y la predicha. Si la clase predicha y el original son diferentes, la instancia se marca como ruido y se

Figura 2. Algoritmo EHT

```

1: Entrada: data RDD de tuplas (clase, atributos)
2: Entrada: P número de particiones
3: Entrada: nTrees número de árboles para Random Forest
4: Entrada: vote estrategia de voto (mayoría o consenso)
5: Salida: RDD filtrado sin ruido
6: partitions  $\leftarrow kFold(data, P)$ 
7: filteredData  $\leftarrow \emptyset$ 
8: for all train, test in partitions do
9:   classifiersModel  $\leftarrow learnClassifiers(train, nTrees)$ 
10:  predictions  $\leftarrow predict(classifiersModel, test)$ 
11:  joinedData  $\leftarrow join(zipWithIndex(predictions), zipWithIndex(test))$ 
12:  markedData  $\leftarrow$ 
13:    map rf, lr, knn, orig  $\in$  joinedData
14:      count  $\leftarrow 0$ 
15:      if rf  $\neq label(orig)$  then count  $\leftarrow count + 1$ 
16:      if lr  $\neq label(orig)$  then count  $\leftarrow count + 1$ 
17:      if knn  $\neq label(orig)$  then count  $\leftarrow count + 1$ 
18:      if vote = majority then
19:        if count  $\geq 2$  then (label =  $\emptyset$ , features(orig))
20:        if count  $< 2$  then orig
21:      else
22:        if count = 3 then (label =  $\emptyset$ , features(orig))
23:        if count  $\neq 3$  then orig
24:      end if
25:    end map
26:  filteredData  $\leftarrow union(filteredData, markedData)$ 
27: end for
28: return (filter(filteredData, label  $\neq \emptyset$ ))

```

devuelven sus atributos y la clase (línea 16).

- El resultado de la función  $map$  anterior es un RDD donde las instancias ruidosas están marcadas. Estas instancias son finalmente eliminadas usando una función  $filter$  y el conjunto de datos resultante es devuelto.

#### II-D. Ensemble Heterogéneo: EHT

El ensemble heterogéneo está inspirado en Ensemble Filter (EF) [12]. Este filtro de ruido usa tres algoritmos de aprendizaje para identificar instancias ruidosas: un árbol de decisión, kNN y un clasificador lineal. Realiza un  $k$ -fold sobre los datos y para cada una de las  $k$  particiones, aprende tres modelos en las otras  $k - 1$  particiones. Cada uno de los clasificadores da una etiqueta a los ejemplos de *test*. Finalmente, usando una votación, se eliminan las instancias ruidosas.

EHT sigue el mismo esquema que EF. La principal diferencia es la elección de los tres algoritmos de aprendizaje: en lugar de un árbol de decisión, usamos Random Forest. Como clasificador lineal se ha usado la Regresión Logística. Finalmente, kNN se ha mantenido como clasificador.

En la Figura 2 se describe el filtrado de ruido en EHT. Los parámetros de entrada son los siguientes: el dataset (*data*), el número de particiones ( $P$ ), el número de árboles para Random Forest (*nTrees*) y la estrategia de voto (*vote*):

- Para cada partición de *train* y *test* del *k*-fold, se aprenden tres modelos: Random Forest, Regresión Logística y 1NN usando *train* como datos de entrada.
- Después se predicen los datos de *test* usando los tres modelos aprendidos. Esto crea un RDD de tripletas (*rf*, *lr*, *knn*) con la predicción de cada algoritmo para cada instancia.
- Las predicción y los datos de *test* se unen por índice para poder comparar las predicciones con la etiqueta original.
- Se comparan las tres predicciones de cada instancia con la etiqueta original usando una función *map* y, dependiendo de la estrategia de voto, las instancias se marcan como ruidosas o limpias.
- Las instancias marcadas como ruidosas son eliminadas usando la función *filter* y el dataset es devuelto.

### III. RESULTADOS EXPERIMENTALES

Esta sección describe los experimentos llevados a cabo sobre cuatro problemas Big Data. En la Sección III-A mostramos los detalles de los datasets y parámetros usados por los filtros de ruido. Los estudios de precisión e instancias eliminadas se encuentran en la Sección III-B. Finalmente, la Sección III-C analiza los tiempos de cómputo de las propuestas.

#### III-A. Framework Experimental

En nuestros experimentos hemos utilizado cuatro datasets de clasificación:

- SUSY, compuesto por 5,000,000 de instancias y 18 atributos. El objetivo es distinguir entre una señal que produce partículas supersimétricas (SUSY) y una que no.
- HIGGS, formado por 11,000,000 de instancias y 28 atributos. Este dataset es un problema de clasificación en el que se distingue una señal que produce bosones de Higgs y otra que no.
- Epsilon, con 500,000 instancias y 2,000 atributos. Este dataset fue creado artificialmente para la Pascal Large Scale Learning Challenge en 2008.
- ECBDL14, con 32 millones de instancias y 631 atributos. Este dataset fue usado como referencia en la competición de machine learning del Evolutionary Computation for Big Data and Big Learning llevado a cabo el 14 de Julio, 2014, bajo la conferencia internacional GECCO-2014. Es un problema de clasificación binaria donde la distribución de clases está altamente desbalanceada: 98 % de instancias negativas. Para este problema, usamos una versión reducida con 1,000,000 de instancias y 30 % de instancias positivas.

Hemos llevado a cabo experimentos en cinco niveles de ruido: en cada uno, un porcentaje de las instancias de entrenamiento han sido alteradas, sustituyendo su clase por otra de las disponibles. Los niveles de ruido elegidos son 0 %, 5 %, 10 %, 15 % y 20 %. Un nivel de 0 % de ruido indica que el dataset no ha sido alterado. Dadas las limitaciones del algoritmo kNN, hemos realizado una validación hold-out.

Hemos elegido 4 particiones para EHO y EHT. Para el filtro heterogéneo, hemos usado dos estrategias de voto: *mayoría*

Tabla I  
PRECISIÓN EN TEST DE KNN. LOS VALORES MÁS ALTOS DE CADA DATASET Y NIVEL RUIDO SE MUESTRAN EN NEGRITA

Dataset Voto	Ruido	Original	EHO	EHT Mayor.	Consen.	ENN
SUSY	0 %	71,79	<b>78,73</b>	77,86	74,64	72,02
	5 %	69,62	<b>78,68</b>	77,68	73,38	69,84
	10 %	67,44	<b>78,63</b>	77,44	72,01	67,66
	15 %	65,27	<b>78,62</b>	77,19	70,52	65,28
	20 %	63,10	<b>78,56</b>	76,93	69,10	63,25
HIGGS	0 %	61,21	<b>64,26</b>	63,94	62,30	60,65
	5 %	60,10	<b>64,06</b>	63,63	61,45	59,60
	10 %	58,97	<b>63,83</b>	63,29	60,65	58,56
	15 %	57,84	<b>63,65</b>	62,86	59,81	57,52
	20 %	56,69	<b>63,53</b>	62,55	58,89	56,45
Epsilon	0 %	56,55	<b>58,11</b>	57,43	55,19	56,21
	5 %	55,71	<b>58,64</b>	57,47	55,47	55,43
	10 %	55,20	<b>58,51</b>	57,26	55,25	54,79
	15 %	54,54	<b>58,39</b>	57,00	55,00	54,30
	20 %	54,05	<b>58,02</b>	56,75	54,72	53,68
ECBDL14	0 %	74,83	<b>76,06</b>	75,12	73,54	73,94
	5 %	72,36	<b>75,60</b>	74,59	72,89	72,77
	10 %	69,86	<b>75,31</b>	74,19	72,50	71,40
	15 %	67,39	<b>75,11</b>	73,99	72,11	69,68
	20 %	64,90	<b>74,82</b>	73,70	71,89	67,64

(mismo resultado para al menos la mitad de los clasificadores) y *consenso* (mismo resultado para todos los clasificadores). Para ENN, con  $k = 5$  tenemos una carga de red mayor, y dada la alta redundancia de datos en Big Data, no hemos apreciado diferencia con respecto a  $k = 1$ . Por esto hemos elegido la opción más eficiente.

Utilizamos dos clasificadores para probar la efectividad de los filtros de ruido, un árbol de decisión y kNN. El árbol de decisión puede adaptar su profundidad para detectar mejor las instancias ruidosas, mientras que kNN es sensible al ruido cuando el número de vecinos es bajo. Para evaluar el rendimiento de los modelos usamos la precisión (número de instancias correctamente clasificadas dividido por el total de instancias). Se ha aumentado la profundidad del árbol de decisión ( $depth = 20$ ) para mejorar la detección de ruido. Para kNN usamos  $k = 1$  ya que es más sensible al ruido.

Los experimentos se han realizado en un clúster compuesto por 20 nodos de cómputo con la siguiente configuración: 2 x Intel Xeon E5-2620, 6 núcleos, 2.00 GHz, 2 TB HDD, 64 GB RAM. Hemos utilizado la siguiente configuración software: Hadoop 2.6.0-cdh5.4.3 de la distribución open source de Apache Hadoop de Cloudera, Apache Spark y MLlib 2.2.0, 460 núcleos (23 núcleos/nodo), 960 RAM GB (48 GB/nodo).

#### III-B. Análisis de Precisión e Instancias Eliminadas

En esta sección se presenta el análisis de los resultados obtenidos por los clasificadores después de aplicar el framework propuesto. Denotamos con *Original* el uso del clasificador sin utilizar ninguna técnica de tratamiento de ruido.

La Tabla I muestra la precisión en test para los cuatro datasets y los cinco niveles de ruido usando kNN como clasificador. En vista de estos resultados podemos señalar que:



Tabla II

PRECISIÓN EN TEST DEL ÁRBOL DE DECISIÓN. LOS VALORES MÁS ALTOS DE CADA DATASET Y NIVEL RUIDO SE MUESTRAN EN NEGRITA

Dataset Voto	Ruido	Original	EHO	EHT Mayor.	Consen.	ENN
SUSY	0 %	80,24	79,78	79,69	<b>80,27</b>	78,56
	5 %	79,94	79,99	80,07	<b>80,36</b>	77,49
	10 %	79,15	79,85	79,81	<b>80,04</b>	77,00
	15 %	78,21	<b>79,81</b>	79,32	79,47	75,81
	20 %	77,09	<b>79,71</b>	79,35	78,95	74,21
HIGGS	0 %	70,17	<b>71,16</b>	69,61	70,41	68,85
	5 %	69,61	<b>71,14</b>	69,34	69,98	68,29
	10 %	69,22	<b>71,06</b>	68,95	69,56	67,52
	15 %	68,65	<b>71,03</b>	68,52	69,04	66,93
	20 %	67,82	<b>71,05</b>	68,18	68,38	66,05
Epsilon	0 %	62,39	<b>66,86</b>	65,13	66,07	61,54
	5 %	61,10	<b>66,64</b>	65,32	66,09	60,41
	10 %	60,09	<b>66,87</b>	65,46	66,11	59,20
	15 %	59,02	<b>66,62</b>	65,33	65,99	58,09
	20 %	57,73	<b>66,46</b>	65,08	65,69	56,71
ECBDL14	0 %	73,98	<b>74,59</b>	74,21	74,51	73,66
	5 %	72,87	<b>74,64</b>	74,16	74,54	73,48
	10 %	71,67	<b>74,59</b>	73,84	74,51	72,75
	15 %	70,28	<b>74,61</b>	73,82	73,91	71,68
	20 %	68,66	<b>74,83</b>	73,78	73,82	70,16

- El uso de cualquier técnica de filtrado de ruido siempre mejora la precisión *Original* para un mismo nivel de ruido. Hay que tener en cuenta que el uso de los filtros de ruido permiten a kNN obtener mejor rendimiento para cualquier nivel de ruido que *Original* a un nivel del 0 % para cualquier conjunto de datos.
- Si nos fijamos en la mejor estrategia de filtrado de ruido para kNN, el filtro homogéneo EHO, permite a kNN obtener los mejores valores de precisión.
- EHT obtiene un rendimiento inferior a EHO. Por otro lado, la estrategia de voto es crucial para EHT, ya que el voto por consenso alcanza una precisión menor, cercana al 2 % con respecto al voto por mayoría.
- Mientras que la precisión para *Original* cae en torno a un 2 % cada 5 % de incremento de ruido, llegando a un total de un 10 % menos precisión al 20 % de ruido, EHO decrece menos de un 1 % en total.
- El método base, ENN, es la peor opción para kNN, ya que obtiene la precisión más baja de los tres filtros de ruido. Para ENN, la precisión cae alrededor de un 2 % cada 5 % de incremento de ruido. Sin embargo, ENN es preferible a no tratar el ruido.

La Tabla II recoge los resultados de precisión en test para los tres métodos de ruido usando un árbol de decisión profundo como clasificador. De estos resultados podemos señalar:

- De nuevo, evitar tratar el ruido no es la mejor opción, ya que usar el filtro adecuado supone una mejora de precisión. Sin embargo, como el árbol de decisión es más robusto al ruido que kNN, no todos los filtros son mejores que si no tratamos el ruido (*Original*). Cuando los filtros eliminan demasiadas instancias, limpias y ruidosas, el árbol de decisión se ve más afectado ya que es capaz

Tabla III

TASA DE REDUCCIÓN (%) PARA EHO, EHT Y ENN

Dataset Voto	Ruido	EHO	EHT Mayoría	Consenso	ENN
SUSY	0 %	20,62	21,04	8,74	49,51
	5 %	23,57	25,09	10,33	49,57
	10 %	26,50	27,94	11,68	49,66
	15 %	29,44	30,85	13,04	49,74
	20 %	32,35	33,71	14,22	49,82
HIGGS	0 %	29,08	35,13	8,20	49,71
	5 %	31,15	36,65	8,83	49,75
	10 %	33,23	38,11	9,59	49,81
	15 %	35,38	39,55	10,35	49,92
	20 %	37,34	41,05	11,11	49,88
Epsilon	0 %	34,31	22,30	2,90	49,97
	5 %	25,32	25,24	4,32	50,01
	10 %	27,80	27,88	5,83	49,97
	15 %	30,79	30,71	7,22	50,01
	20 %	33,52	33,44	8,74	50,17
ECBDL14	0 %	22,44	21,35	5,85	26,58
	5 %	25,80	24,51	8,25	31,06
	10 %	28,49	27,68	10,31	35,07
	15 %	31,13	30,71	12,07	38,63
	20 %	33,86	33,69	13,91	41,60

de tolerar pequeñas cantidades de ruido mientras explora las instancias limpias. kNN se ve más afectado que el árbol de decisión por las instancias ruidosas mantenidas. Por esto, una mala elección del filtro de ruido penalizará el rendimiento del árbol de decisión.

- Para niveles bajos de ruido, EHT puede rendir ligeramente mejor que EHO para algún dataset. Sin embargo, del 10 % en adelante, EHO supera a EHT, haciéndolo el mejor filtro para lidiar con ruido en árboles de decisión.
- Como observamos anteriormente, la precisión *Original* cae con cada incremento de ruido. En este caso, EHO rinde incluso mejor que con kNN, ya que la precisión se mantiene de 0 % al 20 % de ruido.
- En cuanto a la estrategia de voto de EHT, el voto por consenso obtiene mejores resultados que el voto por mayoría. Hay que resaltar que en kNN se ha observado lo contrario: dado que kNN es mucho más sensible y necesita fronteras más limpias (logradas con el voto por mayoría), el árbol de decisión se beneficia de la eliminación de ruido más precisa del voto por consenso.
- ENN, alcanza en torno a un 1 % menos de precisión que el resto para niveles de ruido bajos, incrementándose esta diferencia hasta un 5 % para niveles altos.

Los resultados mostrados han demostrado la importancia de aplicar un filtrado de ruido, independientemente de la cantidad de ruido presente en el dataset. Para explicar mejor por qué EHO es la mejor estrategia de filtrado, debemos estudiar la cantidad de instancias eliminadas.

En la Tabla III mostramos la tasa de reducción de instancias después de aplicar los tres filtros de ruido sobre los cuatro datasets. Cuanto mayor sea el porcentaje de ruido, mayor será la cantidad de instancias eliminadas. Sin embargo, observamos

Tabla IV  
TIEMPO MEDIO DE CÓMPUTO PARA EHO, EHT Y ENN EN SEGUNDOS

Dataset Voto	EHO	EHT Mayoría	Consenso	ENN
SUSY	513,46	5.511,15	5.855,66	8.956,71
HIGGS	587,72	15.300,62	15.232,99	25.441,09
Epsilon	1.868,75	4.120,79	7.201,05	2.718,97
ECBDL14	1.228,24	9.710,70	11.217,02	14.080,03

diferentes patrones dependiendo de la técnica utilizada:

- De media, EHO elimina en torno a un 25 % de instancias al 0 % de ruido. Cada nivel de ruido, se eliminan un 3 % más de instancias.
- En EHT la estrategia de voto tiene un gran impacto en el número de instancias eliminadas. Mientras que el voto por mayoría elimina casi tantas instancias como EHO, el voto por consenso es mucho más conservativo.
- ENN es el filtro que más instancias elimina. De media elimina la mitad de las instancias del dataset al 0 % de ruido, incrementándose un 1 % cada nivel. Este comportamiento tan agresivo lacra el rendimiento de los clasificadores que toleran algo de ruido, como el árbol de decisión.
- EHO es el filtro más equilibrado en términos de instancias eliminadas. A pesar de que la cantidad de instancias eliminadas por EHT con el voto por mayoría es muy similar a EHO, las instancias seleccionadas son diferentes, afectando al clasificador usado posteriormente.

### III-C. Tiempos de Cómputo

Para constituir una propuesta válida en Big Data, este framework también tiene que ser escalable. Esta sección mostramos los tiempos de cómputo de los filtros EHO, EHT y ENN.

En la Tabla IV podemos ver los tiempos medios de ejecución para los tres filtros en segundos. Como el nivel de ruido no es un factor que afecte a estos tiempos, mostramos la media para las cinco ejecuciones realizadas para cada dataset.

Los tiempos medidos muestran que EHO es también el método más rápido. EHO es unas diez veces más rápido que EHT y ENN. Esto se debe al uso del clasificador kNN en EHT y ENN, el cual es un algoritmo muy pesado computacionalmente. Como resultado, EHO es la opción más recomendada para tratar con el ruido en problemas Big Data.

En vista de estos resultados concluimos que:

- El uso de cualquier técnica de filtrado de ruido siempre mejora la precisión *Original* al mismo nivel de ruido.
- EHO ha sido el método que mejor rendimiento ha obtenido para ambos clasificadores. También es el más eficiente términos de tiempo.
- La estrategia de voto tiene un gran impacto en el número de instancias eliminadas en EHT.
- kNN es un método muy pesado computacionalmente, afectando a los tiempos de cómputo de EHT y ENN.

## IV. CONCLUSIONES

Este trabajo presenta el primer filtro de ruido para Big Data, donde la alta redundancia de las instancias y los problemas de

alta dimensionalidad plantean nuevos retos a los algoritmos clásicos de preprocesamiento de ruido. Hemos propuesto dos algoritmos de filtrado de ruido, implementados en un framework Big Data: Apache Spark. Diferentes estrategias de particionamiento y ensembles de clasificadores han llevado a tres enfoques diferentes: un ensemble homogéneo, un ensemble heterogéneo y un enfoque de filtrado simple basado en similitud entre instancias.

La idoneidad de estas técnicas propuestas ha sido analizada utilizando varios conjuntos de datos. El ensemble homogéneo ha demostrado ser el enfoque más adecuado en la mayoría de los casos, tanto en la mejora de la precisión como en la mejora de los tiempos de ejecución. También muestra el mejor equilibrio entre instancias eliminadas y mantenidas.

El problema de ruido en Big Data es un paso crucial en la transformación de estos datos brutos en Smart Data. Con esta propuesta hemos permitido obtener Smart Data a partir de datos imperfectos. Nuestra propuesta puede resolver problemas con millones de instancias y miles de características en poco tiempo, obteniendo datasets limpios de ruido.

## FINANCIACIÓN

Este trabajo está financiado por el Proyecto Nacional TIN2017-89517-P, y el Proyecto BigDaP-TOOLS - Ayudas Fundación BBVA a Equipos de Investigación Científica 2016.

## REFERENCIAS

- [1] X. Zhu and X. Wu, "Class Noise vs. Attribute Noise: A Quantitative Study," *Artificial Intelligence Review*, vol. 22, pp. 177–210, 2004.
- [2] B. Frénay and M. Verleysen, "Classification in the presence of label noise: A survey," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 5, pp. 845–869, 2014.
- [3] B. Zerhari, "Class noise elimination approach for large datasets based on a combination of classifiers," in *Cloud Computing Technologies and Applications (CloudTech), 2016 2nd International Conference on*. IEEE, 2016, pp. 125–130.
- [4] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, Oct 2001.
- [5] M. Hamstra, H. Karau, M. Zaharia, A. Konwinski, and P. Wendell, *Learning Spark: Lightning-Fast Big Data Analytics*. O'Reilly Media, 2015.
- [6] J. Dean and S. Ghemawat, "Mapreduce: Simplified data processing on large clusters," *Communications of the ACM*, vol. 51, no. 1, pp. 107–113, Jan. 2008.
- [7] S. Ramírez-Gallego, A. Fernández, S. García, M. Chen, and F. Herrera, "Big data: Tutorial and guidelines on information and process fusion for analytics algorithms with mapreduce," *Information Fusion*, vol. 42, pp. 51 – 61, 2018.
- [8] J. Lin, "Mapreduce is good enough? if all you have is a hammer, throw away everything that's not a nail!" *Big Data*, vol. 1, no. 1, pp. 28–37, 2013.
- [9] D. García-Gil, S. Ramírez-Gallego, S. García, and F. Herrera, "Principal Components Analysis Random Discretization Ensemble for Big Data," *Knowledge-Based Systems*, vol. 150, pp. 166 – 174, 2018.
- [10] M. Zaharia, M. Chowdhury, T. Das, A. Dave, J. Ma, M. McCauly, M. J. Franklin, S. Shenker, and I. Stoica, "Resilient distributed datasets: A fault-tolerant abstraction for in-memory cluster computing," in *Proceedings of the 9th USENIX Symposium on Networked Systems Design and Implementation (NSDI 12)*. San Jose, CA: USENIX, 2012, pp. 15–28.
- [11] S. Verbaeten and A. Assche, "Ensemble methods for noise elimination in classification problems," in *4th International Workshop on Multiple Classifier Systems*, ser. Lecture Notes on Computer Science, vol. 2709. Springer, 2003, pp. 317–325.
- [12] C. E. Brodley and M. A. Friedl, "Identifying Mislabeled Training Data," *Journal of Artificial Intelligence Research*, vol. 11, pp. 131–167, 1999.



# Un análisis crítico del clasificador $AkDE$ como *ensemble* y sus implicaciones para tratar con grandes volúmenes de datos

Jacinto Arias  
Dpto. de Sistemas Informáticos  
Universidad de Castilla-La Mancha  
Albacete, 02071, España  
jacinto.arias@uclm.es

José A. Gámez  
Dpto. de Sistemas Informáticos  
Universidad de Castilla-La Mancha  
Albacete, 02071, España  
jose.gamez@uclm.es

José M. Puerta  
Dpto. de Sistemas Informáticos  
Universidad de Castilla-La Mancha  
Albacete, 02071, España  
jose.puerta@uclm.es

**Abstract**—En clasificación supervisada el tamaño muestral condiciona enormemente el modelo a utilizar, especialmente para volúmenes de datos masivos donde la eficiencia del modelo y su potencia predictiva constituyen un equilibrio entre rendimiento y complejidad computacional. Los clasificadores basados en Redes Bayesianas permiten ajustarlo parametrizando su aprendizaje para estimar distribuciones de probabilidad cada vez más complejas. El rendimiento puede descomponerse en sesgo, que se reduce al aumentar la complejidad, y varianza, que aumenta de manera inversamente proporcional. El clasificador  $AkDE$  es uno de los ejemplos más estudiados ya que puede aprenderse en una única pasada sobre los datos y al tratarse de un modelo de tipo *ensemble* reduce la varianza agregando las predicciones de clasificadores individuales. En la práctica es necesario reducir su complejidad espacial y es utilizado junto a técnicas de selección de modelos basadas en la Teoría de la Información lo que implica pasadas adicionales sobre los datos. Este trabajo estudia el rendimiento de este clasificador comparándolo a otras técnicas de *ensemble* populares y cuestiona el impacto real de la agregación en la reducción del sesgo y la varianza. Comprobaremos empíricamente como en problemas con muestras grandes los resultados no se ajustan al modelo teórico y cómo la selección de modelos difiere del comportamiento básico de un *ensemble*. Los resultados obtenidos se utilizarán para proponer un modelo alternativo que sí capture las propiedades deseadas para un *ensemble*.

**Index Terms**—Clasificación supervisada; Clasificadores basados en redes Bayesianas; Clasificadores *ensemble*.

## I. INTRODUCCIÓN

La actual abundancia de datos y potencia computacional motiva a los investigadores en aprendizaje automático a desarrollar nuevos métodos buscando el balance entre escalabilidad y precisión. Sin embargo, no deberíamos caer en el error de conseguir este balance a cambio de producir algoritmos complejos de usar y que generen modelos difíciles de interpretar, o de otra manera, no tendrán aceptación por parte de la industria.

De hecho, gran parte de los algoritmos incluidos en los paquetes software que son referencia en la actualidad (e.g.

Este artículo ha sido parcialmente financiado por fondos FEDER y la Agencia Estatal de Investigación (AEI/MINECO) mediante los proyectos TIN2016-77902-C3-1-P y TIN2016-82013-REDT. Jacinto Arias también está financiado por el MECD mediante la beca FPU13/00202.

[12]), fueron propuestos hace más de una década, pero todavía son competitivos. Parte de su éxito, sin duda se debe a sus fundamentos teóricos, pero también a su funcionamiento intuitivo y a la facilidad de interpretar y fijar los hiperparámetros necesarios para su uso. Un ejemplo claro son los clasificadores tipo *ensembles* [9] y, en particular, Random Forest (RF) [5], bien considerados tanto por investigadores como por usuarios. Desde el punto de vista de su usabilidad, el éxito recae en que un único parámetro, el número de modelos en el *ensemble*, sirve para controlar tanto la complejidad del modelo resultante como su nivel de precisión. P.e. en RF está demostrado que incrementar el número de árboles reduce la varianza en la clasificación manteniendo un sesgo estable. Esto garantiza que el rendimiento del clasificador mejorará o se estabilizará con un mayor número de árboles, lo que permite al usuario fijarlo basándose únicamente en la complejidad del problema abordado y/o en los recursos disponibles (tiempo y espacio).

En este trabajo nos centramos en los clasificadores basados en redes Bayesianas (BNCs), los cuáles al poderse aprender *out of core* son, en principio, excelentes candidatos para abordar grandes volúmenes de datos [1]. Además, en algunos de estos algoritmos, un único parámetro,  $k$ , controla la complejidad de los modelos aprendidos. Por ejemplo en el algoritmo  $kDB$  [14], incrementar el valor de  $k$  permite aumentar el número de dependencias permitidas y, por tanto, la complejidad de la red resultante. De forma similar, en el clasificador tipo *ensemble*  $AkDE$  [18], aumentar el valor de  $k$  implica también aumentar el número de dependencias, pero también el número de modelos, por lo que el orden de incremento en la complejidad es incluso superior al caso de  $kDB$ . La implicación, sin embargo, en términos del análisis en términos de sesgo y varianza es diferente: en  $kDB$  aumentar  $k$  permite reducir el sesgo a cambio de incrementar la varianza, mientras que en  $AkDB$  un aumento en  $k$  reduce la varianza pero aumenta mucho la complejidad del modelo resultante. Además, en  $AkDE$  la influencia de incrementar  $k$  se traslada en un aumento de las necesidades computacionales, sobre todo espaciales, que hacen obligatorio realizar una selección de modelos [6], [7], [11] para permitir su uso con bases de datos

de tamaño medio-grande. En este trabajo también estudiamos de forma crítica algunos de los principios en los que se basan estos procesos de selección de modelos.

Aunque el análisis basado en sesgo y varianza es habitual en otro tipo de ensembles, no es común en los ensembles de BNCs, por ello, la novedad de este trabajo reside en que proponemos evaluar los ensembles (y sus modelos constituyentes) de BNCs usando el enfoque de sesgo y varianza, estudiando su comportamiento en dominios de diferente tamaño. Los resultados que obtenemos indican que el algoritmo  $AkDE$  exhibe un comportamiento completamente diferente en muestras grandes que al considerar los benchmark habituales en aprendizaje automático, tradicionalmente formados por conjuntos de pequeño tamaño. Por otra parte, el estudio de los modelos constituyentes del ensemble, nos muestra discrepancias importantes con respecto al funcionamiento interno (y agregado) de otros ensembles típicos como RF. Estas observaciones podrían hacer a los usuarios replantearse la forma que se entiende el clasificador  $AkDE$ , especialmente en el caso de grandes conjuntos de datos. A partir del estudio, proponemos un nuevo ensemble de BNCs que si posee las propiedades esperadas en clasificadores clásicos tipo ensemble como bagging y RF.

El resto del trabajo contiene una breve descripción de los BNCs usados en el estudio, seguido de la descripción del análisis de sesgo y varianza seguido en el artículo y su aplicación al estudio del algoritmo  $AkDE$  desde la perspectiva *ensemble*. A continuación realizamos una experimentación usando tanto datos masivos como benchmarks clásicos en aprendizaje automático para evaluar los clasificadores objeto del estudio. Por último, a la luz de los resultados, proponemos un ensemble de BNCs cuyo comportamiento se asemeja más a los ensembles clásicos (bagging y RF).

## II. CLASIFICADORES BASADOS EN REDES BAYESIANAS

El problema de clasificación supervisada consiste en predecir la *etiqueta*  $y \in \Omega_Y = \{y_1, \dots, y_c\}$  para la variable de respuesta (o clase)  $Y$ , para un ejemplo  $\mathbf{x} = (\mathbf{x}_1, \dots, \mathbf{x}_d)$  definido sobre  $d$  atributos  $\{X_1, \dots, X_d\}$ . Para resolverlo, el objetivo es inducir un modelo (o clasificador) a partir de un conjunto de datos formado por  $m$  ejemplos previamente *etiquetados*  $D = \{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ .

El formalismo de las Redes Bayesianas (RBs) [13] usa un grafo dirigido acíclico (DAG) para representar de forma eficiente la distribución de probabilidad conjunta (DPC) definida sobre el conjunto de variables. En particular una RB factoriza la DPC mediante el producto  $p(y, \mathbf{x}) = \prod_{i=1}^d \mathbf{p}(\mathbf{x}_i | \pi_{\mathbf{x}_i})$ , donde  $\pi_{\mathbf{x}_i}$  denota el conjunto de padres del atributo  $X_i$  en el DAG. Desde un punto de vista probabilístico, la etiqueta a asignar a un ejemplo  $\mathbf{x}$  es la que maximiza la probabilidad a posteriori, es decir,  $\arg \max_{y \in \Omega_Y} p(y | \mathbf{x})$ .

En la práctica, los algoritmos que han demostrado un mejor rendimiento en esta tarea son los denominados BNCs [3], redes Bayesianas cuya estructura otorga un papel distinguido a la variable clase y que limitan de distinta forma el número de dependencias permitido. De ellos, el más popular por su simplicidad es Naive Bayes (NB), que asume que todas las

variables predictoras son independientes dada la clase. Sin embargo, la suposición realizada resta capacidad discriminativa a NB lo que lo convierte en un clasificador con mucho sesgo. Otros modelos de BNCs se basan en imponer la estructura base de NB pero permitiendo algunas dependencias adicionales entre las variables predictoras.

### A. $k$ -dependence BN Classifier ( $kDB$ )

El algoritmo  $kDB$  [14] se basa en el uso de estimadores  $k$ -dependientes, es decir, cada variable puede depender de otros  $k$  atributos y de la clase. Requiere aprendizaje estructural y el modelo producido es una única RB.

El algoritmo propuesto en [14] usa los conceptos de información mutua (MI) e información mutua condicional (CMI) para guiar el proceso de aprendizaje estructural. Primero se ordenan las variables en función de  $I(X_i; C)$ . Después, a la variable  $i$ -ésima de dicho orden se le ponen como padres en el grafo la variable clase  $C$  y las  $k$  variables  $X_j$  con mayor  $I(X_j, X_i | C)$ , t.q. sólo se consideran las que preceden a  $X_i$  en el orden. La posterior estimación de parámetros requiere una pasada adicional por los datos cuando  $k \geq 2$ .

Fijando adecuadamente el valor de  $k$  se mejora el ajuste del modelo a los datos, sin embargo, aumentar  $k$  implica también obtener modelos más complejos, habitualmente con menor sesgo pero mayor varianza debido al sobreajuste. En [11] se estudia que en bases de datos grandes el riesgo de sobreajuste (e incremento de la varianza) disminuye considerablemente. El algoritmo  $kDB$  *selectivo* ( $SkDB$ ) combate la complejidad del modelo eligiendo el  $k$  adecuado para cada variable [11], lo que requiere una pasada adicional por los datos.

### B. Averaged $k$ Dependence Estimators

El clasificador  $AkDE$  puede modelarse como un ensemble formado por un conjunto de BNCs  $H = \{h_i(\pi_i), i = 1, \dots, K\}$ , donde el número de modelos  $K$  se fija restringiendo el espacio de los posibles modelos a una familia de clasificadores  $k$ -dependientes. En particular, cada modelo es un NB aumentado en el que además de depender de la clase, todos los atributos dependen de un conjunto fijo (el mismo para todos) de  $k$  padres, denotado por  $\pi_i$ . El ensemble consiste entonces en la familia *completa* de este tipo de clasificadores, por lo que  $K = \binom{d}{k}$ . La etapa de inferencia consiste en promediar la distribución de probabilidad de la clase a posteriori en todos los clasificadores del ensemble. Como caso particular, el clasificador AIDE (AODE) asume que todos los atributos dependen de la clase y otro atributo, conocido como *super padre* (SP). En AODE los modelos constituyentes se conocen como SPODE y en general como  $SPkDE$ . Al fijarse la estructura, no se requiere aprendizaje estructural, siendo un clasificador *out of core* real.

Al igual que en  $kDB$ , en  $AkDE$  podemos ajustar el balance sesgo-varianza variando el parámetro  $k$ , lo que permite representar desde clasificadores con mucho sesgo y poca varianza como NB (A0DE), hasta clasificadores con poco sesgo pero alta varianza, obtenidos al incrementar  $k$  y poder usar distribuciones de probabilidad de alta dimensionalidad



[18]. Sin embargo, en el caso de  $AkDE$  la influencia de incrementar  $k$  en la complejidad del modelo resultante se traslada al incremento del tamaño de las tablas de probabilidad y, sobre todo, al incremento en el número de modelos del ensemble. Por ejemplo, con 100 variables predictoras  $A1DE$  contendrá 100 modelos individuales pero  $A2DE$  contendrá 5000. Indudablemente esto representa un problema muy importante de cara a la escalabilidad del algoritmo en problemas de media-alta dimensionalidad (número de variables) por lo que se han propuesto diferentes soluciones basadas en realizar selección de modelos [6], [7], [11]. Es importante remarcar que si en  $kDB$  la selección de modelos tenía como objetivo un mejor ajuste de los datos, en  $AkDE$  la selección de modelos es obligatoria para convertirlo en un modelo usable en la práctica.

Estas técnicas de selección de modelos se basan en una aproximación híbrida entre el enfoque filter y wrapper, guiados por el uso de conceptos de Teoría de la Información, mayormente Información Mutua (MI). En particular, los algoritmos *Sample Attribute Selective AkDE (SASAkDE)* [6] y *Selective AkDE (SAkDE)* [7] han mostrado que es posible reducir la complejidad espacial, pero también (sorprendentemente) obtener mejor predicción (accuracy) que el ensemble formado por la familia completa de  $SPkDEs$ . Sin embargo, también hay algunos puntos débiles que deben ser estudiados: (1) este proceso añade pasadas adicionales por los datos, lo que supone un inconveniente en el caso de grandes muestras (e.g. big data); (2) la idea subyacente es asumir que la información mutua condicional del conjunto de super-padres dada la clase es un buen indicador del rendimiento en términos de clasificación del sub-modelo resultante. En este trabajo analizamos empíricamente esta hipótesis; y (3) volviendo a nuestra discusión inicial y las ventajas de tener hiperparámetros interpretables, indicar que este proceso de selección de modelos también añade cierta confusión al proceso, puesto que a igual  $k$  la complejidad del modelo resultante puede diferir mucho de un problema a otro.

### III. SESGO Y VARIANZA EN CLASIFICACIÓN

Distintos estudios [2], [4] han analizado la capacidad predictiva de los clasificadores ensemble mediante la descomposición del error en términos de *sesgo* y *varianza*. Intuitivamente, un algoritmo de aprendizaje *sesgado* muestra un error persistente (similar) al entrenar con distintos conjuntos de datos, mientras que un algoritmo con alta varianza muestra un error que fluctúa entre los distintos conjuntos de datos.

Breiman [4] presenta una taxonomía de clasificadores estables (poca varianza a riesgo de tener mucho sesgo) e inestables (poco sesgo y alta varianza). Los clasificadores inestables, *en media* tienen un buen rendimiento, lo que les convierte en el marco ideal para los ensembles basados en voto por la mayoría, puesto que su uso consigue reducir la varianza [4]. Ejemplos son RF o bagging con árboles de decisión, que son algoritmos estado-del-arte en clasificación supervisada. Por otra parte, los modelos inestables son buenos candidatos para su aplicación en problemas grandes [11], ya que el impacto de la varianza se suaviza al disponer de más datos.

Sin embargo, la descomposición del error en sesgo y varianza proviene de la regresión numérica, y aunque su interpretación es también intuitiva en el caso de la clasificación, su aplicación no lo es. De hecho, mientras que en regresión promediar funciones independientes reduce la varianza sin modificar el sesgo, en clasificación promediar los modelos podría incrementar el error de clasificación [15].

Existen distintas formulaciones de la descomposición en sesgo/varianza [15], [16]. En este trabajo hemos optado por la implementación realizada en [16]<sup>1</sup> de la descrita en [2], [4]. Las métricas utilizadas se obtienen a partir de la estabilidad de un clasificador  $\mathcal{L}$  cuando se entrena y testea repetidamente sobre un número de conjuntos de datos  $\mathcal{T}$ . Definimos la tendencia central  $C_{\mathcal{L}\mathcal{T}}^{\circ}(\mathbf{x})$  como la clase con máxima probabilidad de ser seleccionada para un ejemplo determinado  $\mathbf{x}$  por parte de todos los clasificadores aprendidos a partir de  $\mathcal{T}$ :  $C_{\mathcal{L}\mathcal{T}}^{\circ}(\mathbf{x}) = \arg \max_y P_{\mathcal{T}}(\mathcal{L}(\mathbf{x}) = y)$

El sesgo puede entonces medirse como el error introducido por la tendencia central del algoritmo, es decir, el error de la clasificación más frecuente, mientras que la varianza es el error introducido por la desviación de dicha tendencia central. Habitualmente se habla de estos valores en términos de *contribución* del sesgo y la varianza al error de clasificación, ya que éste puede expresarse como la suma de ambos. Para calcularlos, primero se obtiene una estimación de la tendencia central a partir de nuestra muestra  $\mathcal{D}$ , para lo que se ejecuta una 10x3 validación cruzada, induciendo así 30 modelos  $\mathcal{L}(T_k^i)$  y el correspondiente conjunto de test  $f_k^i$  para cada una de las  $i \in \{1, \dots, 10\}$  repeticiones y  $k \in \{1, 2, 3\}$  conjuntos (folds) de entrenamiento. Por tanto, se obtienen 10 predicciones independientes para cada instancia  $\mathbf{x}$  y fijamos la tendencia central  $C_{\mathcal{L}\mathcal{T}}^{\circ}(\mathbf{x})$  para dicho ejemplo como la media. Formalmente, la tendencia central se obtiene como:

$$C_{\mathcal{L}\mathcal{T}}^{\circ}(\mathbf{x}) = \arg \max_y P \left( \sum_{i=1}^{10} \sum_{k=1}^3 1 [\mathbf{x} \in f_k^i \wedge \mathcal{L}(T_k^i)(\mathbf{x}) = y] \right)$$

La contribución del sesgo y la varianza al error se calculan para cada instancia y se agregan para todo el conjunto de datos:

$$\begin{aligned} \text{sesgo} &= P_{(\mathbf{x}, y), \mathcal{T}}(\mathcal{L}(\mathcal{T})(\mathbf{x}) \neq y \wedge \mathcal{L}(\mathcal{T})(\mathbf{x}) = C_{\mathcal{L}\mathcal{T}}^{\circ}(\mathbf{x})) \\ \text{varianza} &= P_{(\mathbf{x}, y), \mathcal{T}}(\mathcal{L}(\mathcal{T})(\mathbf{x}) \neq y \wedge \mathcal{L}(\mathcal{T})(\mathbf{x}) \neq C_{\mathcal{L}\mathcal{T}}^{\circ}(\mathbf{x})) \end{aligned}$$

### IV. $AkDE$ BAJO LA PERSPECTIVA DE UN ENSEMBLE

Entre los modelos ensemble más populares encontramos el clasificador RF [5] basado en agregar el voto de árboles de decisión aplicando Bagging: Aprender cada modelo a partir de una muestra obtenida realizando bootstrapping, y Random Subspaces: Seleccionar un conjunto de nodos subóptimo a la hora de estimar la partición de cada nodo del árbol. Esto incrementa la diversidad de los modelos de un modo predecible, especialmente en árboles completamente desarrollados. El estudio original demuestra que, si se incluyen modelos

<sup>1</sup>Esta metodología se ha usado p.e. para estudiar la propuesta inicial del clasificador  $AkDE$  [17], [18]

suficientes el sesgo del ensemble converge asintóticamente a niveles relativos a un árbol de decisión individual.

En el caso de  $AkDE$  se aprende un número finito de modelos en función de  $k$ , imponiendo una cota para la reducción de varianza y siendo imposible estabilizar el sesgo asintóticamente. Un número fijo de modelos reducirá al mismo tiempo la diversidad, deteriorando los resultados de la agregación. Además, los modelos del ensemble no se aprenden mediante una estrategia aleatoria subóptima sino que su estructura se fija heurísticamente conforme a cada super-padre. En general un clasificador  $k$ -dependiente  $H$  reduce el sesgo ajustando su estructura de la manera más fiel posible a un modelo óptimo sin restringir  $H'$ , mientras que en el caso de  $AkDE$  no hay garantía de que las distribuciones de probabilidad modeladas aproximen a dicho clasificador, por lo que podemos asumir que muchos parámetros impactarán negativamente en el sesgo.

La literatura muestra que  $AkDE$  obtiene baja varianza en la práctica, sin embargo, no existe evidencia de que esto sea un resultado directo de la agregación o es inherente a los modelos individuales. Para profundizar realizaremos un experimento, para nuestro conocimiento inédito, evaluando la contribución particular al error de sesgo y varianza para una colección de ensembles y los modelos que los componen.

#### A. Sesgo y la Varianza en Problemas de Gran Tamaño

Un BNC con bajo sesgo es idóneo para grandes volúmenes de datos ya que obtendrá distribuciones de probabilidad mejor calibradas. Para determinar el sesgo de un modelo podemos medir su estabilidad para muestras de tamaño incremental. Para ello utilizaremos la base de datos sintética *pokerhand* [8] como benchmark, evaluando la descomposición en sesgo y varianza del error sobre 20 muestreos desde 50k instancias hasta  $1M^2$ .

En la Figura 1 podemos ver que RF obtiene menor varianza que los modelos individuales, mientras que es máxima en el caso de árbol totalmente desarrollado. Al contrario, un árbol sin aleatorizar, es un modelo menos sesgado que el ensemble por estar compuesto por modelos que no se ajustan perfectamente a los datos. No obstante, la suma confirma que el ensemble es el de menor error y mayor estabilidad, especialmente para dominios pequeños donde la varianza es más difícil de reducir. En los modelos BNC confirmamos que los modelos con mayor sesgo como naive Bayes o  $kDB$  con  $k = 1$  no mejoran conforme el tamaño de la muestra aumenta, mientras que al aumentar  $k$  la mejora es clara y constante, en presencia de suficientes datos que permitan calibrar los parámetros correctamente. Respecto a la varianza, confirmamos que los modelos sencillos son más estables, mientras que los clasificadores complejos requieren de más datos para estabilizarse.

Aunque los resultados para A1DE deberían ser superiores a los de  $kDB$  con  $k = 1$  o  $k = 2$ , vemos que empeoran al

<sup>2</sup>Experimentos realizados en un cluster Apache Spark de 7 nodos con procesadores hexacore Intel Xeon E5-2609v3 1.90GHz y 64GB de RAM. El software está basado en [1] y el código está disponible en <http://github.com/jacintoArias/pgm2018>.

umentar la muestra. Si utilizamos el voto por la mayoría en lugar de la agregación numérica de probabilidades, Figura 1 bajo el nombre *alde-majority*, vemos que la agregación de probabilidades suaviza el error cometido por los modelos de peor calidad, mientras que el voto por la mayoría los imita, implicando que si hay más modelos sesgados que acertados el ensemble lo estará también. Un tamaño de muestra mayor calibra las probabilidades de dichos modelos hacia valores extremos, convirtiendo al ensemble en un modelo equivalente al voto por la mayoría para muestras grandes.

#### B. Diseño Alternativo de Ensembles Basados en BNCs

Recientemente se han propuesto ensembles de BNCs alternativos, dado que en la práctica  $AkDE$  requiere aplicar selección de modelos y con ello una fase de aprendizaje adicional, podemos utilizar otros modelos que ya la realizan como  $kDB$ . Cabe destacar el clasificador  $kDF$  ( $k$ -dependent forest) [10] basado en construir un ensemble compuesto por  $n$  modelos  $kDB$ , uno para cada atributo  $X$  donde se aplica un proceso de ordenación de los atributos más sofisticado que introduce diversidad. Aunque esta propuesta supera en rendimiento a A1DE sufre de los mismos problemas descritos anteriormente ya que solo considera un número finito de modelos obtenidos de un modo no aleatorio.

Un modelo ensemble basado en agregación o voto por mayoría debería capturar ambas propiedades, para lo que proponemos una alternativa básica, el clasificador  $k$ -dependiente aleatorio ( $RkDB$ ). Este ensemble tendrá  $h \in [1, \text{inf}]$  modelos independientes aprendidos por una versión alterada de  $kDB$ , considerando solo un subconjunto en una proporción  $\alpha \in [0, 1]$  de los padres disponibles para cada nodo en cada modelo, tomando como inspiración el particionado subóptimo que realiza RF. Así, añadimos diversidad mediante aleatoriedad controlada, preservando el sesgo del clasificador original.

#### C. Sesgo y Varianza en los Modelos Individuales

En nuestro segundo experimento evaluaremos el comportamiento de la descomposición del error para un benchmark clásico (véase la Tabla I) obtenido a partir del repositorio UCI [8]. Este conjunto de problemas es el utilizado en la mayoría de propuestas basadas en el clasificador  $AkDE$ . Estos modelos han obtenido siempre un buen rendimiento en este contexto, como hemos podido reproducir según muestran los resultados de la Tabla II. Comprobamos que no existe diferencia significativa entre el rendimiento de A1DE y RF y la nueva propuesta  $RkDB$  cuando  $k=1$ , no obstante para sucesivos valores de  $k$  los resultados empeoran, lo que achacamos al reducido tamaño de muestra de los problemas que conforman el benchmark. Si se observa la Figura 1 podemos comprobar que ocurre lo mismo en muestras de poco tamaño.

A la vista de que los ensembles mejoran a los modelos individuales, estudiaremos el efecto de la agregación en la descomposición en sesgo y varianza. La Figura 2 muestra la distancia entre el ensemble y los modelos individuales, podemos ver como RF reduce la varianza como esperábamos seguido de  $RkDB$ , mientras que en A1DE esta reducción es

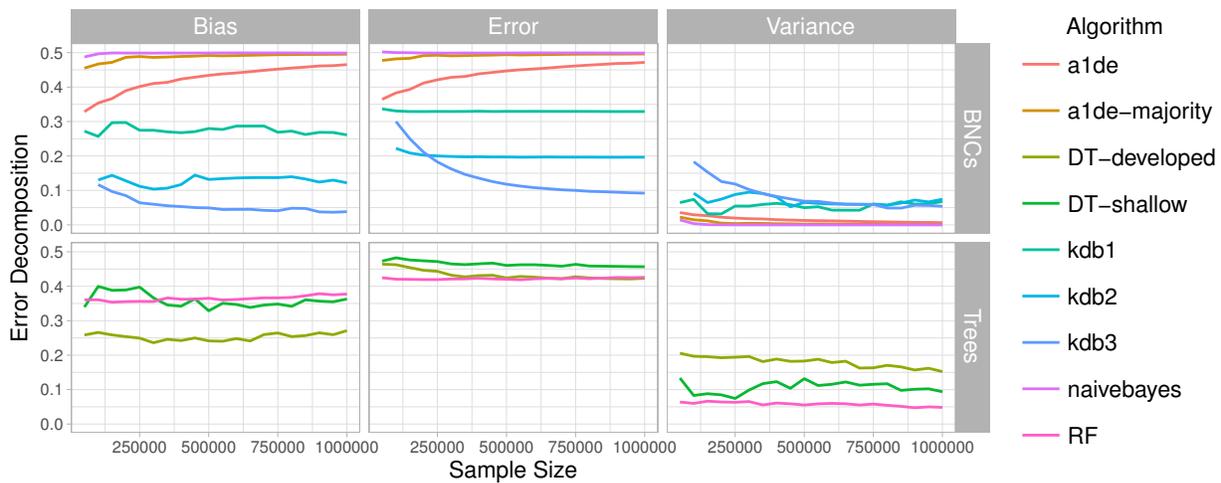


Figura 1. Evolución de sesgo y varianza para experimentos repetidos sobre muestras de mayor tamaño incrementalmente. La gráfica muestra en el eje y los valores para varianza, sesgo y error de izquierda a derecha, para la familia de modelos BNC en la parte superior y los basados en árboles en la inferior.

Problema	Casos	Atr.	Etiqu.	Problema	Casos	Atr.	Etiqu.	Problema	Casos	Atr.	Etiqu.
Pokerhand	1000000	10	8	Car	1728	8	4	Soybean	307	35	15
Adult	48842	15	2	Contraceptive-mc	1473	10	3	Haberman	306	3	2
Chess	28056	6	18	German	1000	21	2	HeartDisease-c	303	14	2
Letter	20000	17	26	Vowel	990	14	11	Audiology	226	70	24
Nursery	12960	9	5	Tic-Tac-Toe	958	10	2	New-Thyroid	215	6	3
PenDigits	10992	17	10	Anneal	898	39	6	Glass-id	214	10	3
CensusIncome	10419	14	2	Vehicle	846	19	4	Sonar	208	61	2
Mushrooms	8124	23	2	PimaIndiansDiabetes	768	9	2	Autos	205	26	7
Musk	6598	168	2	BreastCancer-w	699	10	2	Wine	178	14	3
OpticalDigits	5620	49	10	BalanceScale	625	5	3	Hepatitis	155	20	2
PageBlocks	5473	11	5	CreditApproval	690	15	2	TeachingAssistant	151	6	3
Spambase	4601	58	2	Cylinder-bands	512	39	2	Iris	150	5	3
Hypothyroid	3772	30	4	Haberman	306	3	2	Promoters	106	58	2
Kr.vs.kp	3196	37	2	HouseVotes84	435	17	2	Zoo	101	17	7
Splice	3190	62	3	HorseColic	368	22	2	Post-operative	90	9	3
Segment	2310	20	7	Ionosphere	351	35	2	LaborNegotiations	57	17	2
Mfeat	2000	6	2	PrimaryTumor	339	18	22	LungCancer	32	57	3

Tabla I

PROPIEDADES DE LOS PROBLEMAS UTILIZADOS EN LOS EXPERIMENTOS. LOS ATRIBUTOS CONTINUOS HAN SIDO DISCRETIZADOS EN CUATRO INTERVALOS POR IGUAL FRECUENCIA PARA LOS MODELOS BNC.

casi imperceptible, incluso la mejora parece venir de una reducción en sesgo. Observando una muestra de estas diferencias a nivel individual, Figura 3, podemos ver dos distribuciones muy diferentes, muy consistente en el caso de RF y RkDB pero casi aleatoria en A1DE. Este experimento saca a luz que A1DE al no seguir los mismos principios de diseño que otros ensembles tampoco se comporta de la manera esperada, lo que explica porque la selección de subconjuntos puede mejorar el rendimiento respecto al conjunto entero, una propiedad nada deseable y difícil de controlar en un ensemble [15].

#### D. Sobre la Efectividad de la Selección de Modelos

Hemos observado baja consistencia en los modelos que componen un ensemble  $A_kDE$ , donde unos modelos muestran propiedades deseables como bajo sesgo mientras que otros parecen ser propensos a error y tienen poco margen de varianza que reducir. Los algoritmos de selección de modelos introducidos aprovechan esta circunstancia para reducir el espacio de modelos y al mismo tiempo mejorar su rendimiento utilizando heurísticas basadas en la hipótesis de que la Información Mutua (MI) entre los atributos predictores que guían los modelos y la clase es un buen indicador de su rendimiento.

Cabe realizar entonces la pregunta de si estos métodos seleccionan entonces aquellos clasificadores propensos a mejorar en la agregación, poco sesgo y mayor varianza, o solo aquellos que minimizan el error independientemente. Para responder empíricamente hemos evaluado diversos criterios de selección de modelos de manera incremental, es decir, añadiendo cada vez un modelo adicional. Se han evaluado tres criterios wrapper: mínimo error, bias y varianza; un criterio filter basado en MI y un criterio aleatorio para establecer una base de comparación. La Tabla III muestra la suma del

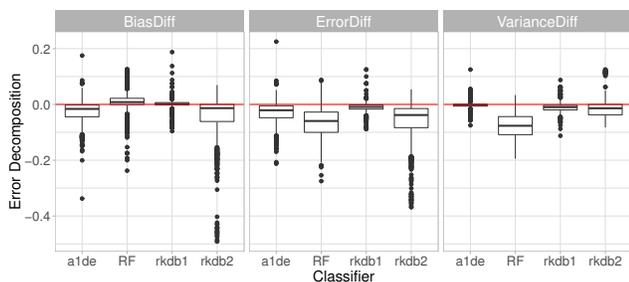


Figura 2. Distribución de las diferencias en la descomposición del error entre el modelo agregado y los diferentes modelos individuales. La línea roja en  $y=0$  ayuda a distinguir entre diferencias positivas y negativas.



Figura 3. Distribución bidimensional de sesgo (x) y varianza (y) para los modelos individuales (cruces azules) y el ensemble (punto rojo).

error sobre todos los incrementos para cada criterio y base de datos del benchmark anterior. Los resultados muestran que los mejores criterios son aquellos que minimizan el error o su componente del sesgo, mientras que la varianza, la IM y el resultado aleatorio son equivalentes. Esta evidencia reafirma nuestra hipótesis y revela que los criterios filter basados en Información Mutua pueden no ser los más acertados.

## V. CONCLUSIONES Y TRABAJO FUTURO

Hemos visto que los buenos resultados de  $AkDE$  en la práctica son inconsistentes con la definición de un ensemble, y que la mejora en rendimiento al seleccionar modelos solo es relevante en la aplicación de técnicas wrapper que son

Algorithm	rank	pvalue	win	tie	loss
A1DE	2.48	-	-	-	-
RF	2.49	<b>9.7929e-01</b>	26	0	27
RkDB1	2.76	<b>8.7224e-01</b>	30	2	21
kDB1	3.58	7.1644e-03	37	0	16
RkDB2	4.75	1.8647e-09	46	0	7
kDB2	4.93	7.4299e-11	46	1	6

Tabla II

LAS COLUMNAS GANA, EMPATA Y PIERDE COMPARAN EL ERROR OBTENIDO POR EL MEJOR MODELO (A1DE) CONTRA LOS DEMÁS (P.E., A1DE GANA 24 VECES CONTRA RF Y PIERDE 17). EL RANGO Y EL P-VALOR CORRESPONDEN AL TEST DE FRIEDMAN Y POST-HOC (HOLM) CON  $\alpha = 0.05$ . EN NEGRITA LAS HIPÓTESIS RECHAZADAS.

Criterio	Rango	p-valor	Gana	Empata	Pierde
error	1.52	-	-	-	-
bias	1.83	<b>3.6273e-01</b>	24	3	17
mi	3.75	7.8353e-11	43	0	1
variance	3.81	3.7139e-11	41	1	2
random	4.09	1.0269e-13	43	0	1

Tabla III

COMPARATIVA DE LA SUMA DEL ERROR PARA DISTINTOS CRITERIOS DE SELECCIÓN EN A1DE. MÉTRICAS DESCRITAS EN LA TABLA II.

muy costosas de computar en un escenario real. En su lugar hemos propuesto y comparado favorablemente un clasificador sencillo de tipo ensemble basado en BNCs. Los resultados muestran que es comparable a  $AkDE$  y que proporciona un recorrido de mejora que exploraremos en trabajos posteriores, especialmente en problemas de gran tamaño, donde hemos visto una clara superioridad del clasificador básico  $kDB$  en calibración de probabilidades y reducción del sesgo.

## REFERENCES

- [1] Jacinto Arias, Jose A. Gamez, and Jose M. Puerta. Learning distributed discrete Bayesian Network Classifiers under MapReduce with Apache Spark. *Knowledge-Based Systems*, 117:16 – 26, 2017.
- [2] Eric Bauer, Ron Kohavi, Philip Chan, Salvatore Stolfo, and David Wolpert. An Empirical Comparison of Voting Classification Algorithms: Bagging, Boosting, and Variants. *Machine Learning*, 36:105–139, 1999.
- [3] Concha Bielza and Pedro Larrañaga. Discrete Bayesian Network Classifiers: A Survey. *ACM Comput. Surv.*, 47(1):5:1–5:43, jul 2014.
- [4] Leo Breiman. Arcing classifiers. *Annals of Statistics*, 26(3):801–849, 1998.
- [5] Leo Breiman. Random forests. *Machine Learning*, 45(1):5–32, 2001.
- [6] Shenglei Chen, Ana M. Martinez, Geoffrey I. Webb, and Limin Wang. Sample-Based Attribute Selective AnDE for Large Data. *IEEE Transactions on Knowledge and Data Engineering*, 29(1):172–185, 2017.
- [7] Shenglei Chen, Ana M. Martinez, Geoffrey I. Webb, and Limin Wang. Selective AnDE for large data learning: a low-bias memory constrained approach. *Knowledge and Information Systems*, 50(2):475–503, 2017.
- [8] Dua Dheeru and Efi Karra. UCI Machine Learning Repository, 2017.
- [9] Thomas G. Dietterich. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees. *Machine Learning*, 40:139–157, 2000.
- [10] Zhiyi Duan and Limin Wang. K-Dependence Bayesian Classifier Ensemble. *Entropy*, 19(12), 2017.
- [11] A M Martínez, G I Webb, S Chen, and N A Zaidi. Scalable learning of Bayesian network classifiers. *Journal of Machine Learning Research*, 17:1–30, 2016.
- [12] Xiangrui Meng, Joseph Bradley, Burak Yavuz, Evan Sparks, Shivaram Venkataraman, Davies Liu, Jeremy Freeman, DB Tsai, Manish Amde, Sean Owen, Doris Xin, Reynold Xin, Michael J. Franklin, Reza Zadeh, Matei Zaharia, and Ameet Talwalkar. MLlib: Machine Learning in Apache Spark. *Journal of Machine Learning Research*, 17(34):1–7, 2016.
- [13] Judea Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. 2014.
- [14] Mehran Sahami. Learning Limited Dependence Bayesian Classifiers. In *Proc. of the 2nd Int. Conf. on Knowledge Discovery and Data Mining, KDD'96*, pages 335–338. AAAI Press, 1996.
- [15] Robert E. Schapire, Yoav Freund, Peter Bartlett, and Wee Sun Lee. Boosting the margin: A new explanation for the effectiveness of voting methods. *Annals of Statistics*, 26(5):1651–1686, 1998.
- [16] Geoffrey I. Webb. MultiBoosting: a technique for combining boosting and wagging. *Machine Learning*, 40(2):159–196, 2000.
- [17] Geoffrey I. Webb, Janice R. Boughton, and Zhihai Wang. Not so naive Bayes: Aggregating one-dependence estimators. *Machine Learning*, 58(1):5–24, 2005.
- [18] Geoffrey I. Webb, Janice R. Boughton, Fei Zheng, Kai Ming Ting, and Houssam Salem. Learning by extrapolation from marginal to full-multivariate probability distributions: Decreasingly naive Bayesian classification. *Machine Learning*, 86(2):233–272, oct 2012.



# Un enfoque aproximado para acelerar el algoritmo de clasificación Fuzzy kNN para Big Data

Jesús Maillo, Julián Luengo, Salvador García, Francisco Herrera  
 Dept. de Ciencias de la Computación e Inteligencia Artificial  
 Universidad de Granada. 18071, Granada, España  
 Email: {jesusmh, julianlm, salvagl, herrera}@decsai.ugr.es

Isaac Triguero  
 School of Computer Science  
 University of Nottingham, Jubilee Campus  
 Nottingham NG8 1BB, United Kingdom  
 Email: Isaac.Triguero@nottingham.ac.uk

**Resumen**—El clasificador difuso de los  $k$  vecinos más cercanos (Fuzzy  $k$  Nearest Neighbor - Fuzzy kNN) es reconocido por su eficacia en problemas de aprendizaje supervisado. El algoritmo kNN clasifica comparando una nueva instancia con los datos etiquetados mediante una función de similitud. Su versión difusa se compone de dos etapas. La primera etapa calcula el grado de pertenencia a cada clase para cada instancia del problema, con el objetivo de detectar con mayor precisión las fronteras entre clases. La segunda etapa clasifica siguiendo el mismo esquema que el algoritmo kNN, aunque haciendo uso del grado de pertenencia a clase previamente calculado. La propuesta existente de Fuzzy kNN para afrontar conjuntos de datos muy grandes no es completamente escalable, debido a que replica el comportamiento de Fuzzy kNN original. Con el objetivo de agilizar este algoritmo, en esta contribución se propone un enfoque aproximado que acelera los tiempos de ejecución sin perder calidad en la clasificación, mediante el uso de árboles e implementado en Spark. En la experimentación realizada se comparan varios enfoques de Fuzzy kNN para big data, con conjuntos de datos de hasta 11 millones de instancias. Los resultados muestran una mejora en tiempo de ejecución y precisión con respecto al modelo de la literatura.

**Palabras Clave**—Conjuntos difusos, K-vecinos más cercanos, Clasificación, MapReduce, Apache Spark, Big Data

## I. INTRODUCCIÓN

El algoritmo de los  $k$  vecinos más cercanos ( $k$  Nearest Neighbor - kNN) [1] es catalogado como clasificador basado en instancias. Para clasificar, compara las instancias no vistas con aquellas etiquetadas del conjunto de entrenamiento utilizando una función de similitud. Generalmente la similitud es medida mediante una función de distancia (Euclídea o Manhattan). A pesar de su simplicidad, el clasificador kNN es uno de los diez algoritmos de clasificación más relevantes [2].

Sin embargo, kNN suponiendo todos los vecinos igual de importantes en la clasificación, considerando que las fronteras entre clases están perfectamente definidas. Existen diferentes propuestas basadas en la teoría de los conjuntos difusos que abordan este problema. En [3], el algoritmo clásico Fuzzy kNN [4] destaca como uno de los enfoques más eficaces. Fuzzy kNN se compone de dos etapas: cálculo de grado de pertenencia y clasificación. La primera etapa, cambia la etiqueta de la clase por un grado de pertenencia a cada clase, de acuerdo a las instancias más cercanas. La segunda etapa, calcula el kNN con la información del grado de pertenencia.

Así, se consigue detectar con mayor precisión las fronteras, viéndose menos afectado por el ruido y mejorando al kNN en la mayoría de los problemas de clasificación.

En el ámbito del big data, tanto el algoritmo kNN como Fuzzy kNN encuentran problemas para manejar grandes conjuntos de datos con respecto al tiempo de ejecución y al consumo de memoria. Existe una propuesta exacta del algoritmo kNN para abordar problemas big data y se denomina  $k$  Nearest Neighbor - Iterative Spark (kNN-IS) [5]. Además de esta versión exacta, también existen versiones aproximadas que reducen los tiempos de ejecución: Metric-Tree [6] y Spill-Tree. En [7], los autores estudian estos modelos y proponen el modelo Hybrid Spill-Tree (HS) como hibridación de ambos con el objetivo de mejorar el tiempo de ejecución sin afectar a los resultados debido a la redundancia de datos implícita en big data. Por otro lado, existe una solución exacta para aplicar Fuzzy kNN en big data, *Global Exact Fuzzy k Nearest Neighbors* (GE-FkNN) [8]. Aunque es capaz de escalar hasta conjuntos de datos muy grandes, los tiempos de ejecución de la primera etapa son sustancialmente altos, provocando un cuello de botella. Sin embargo, no se han aplicado enfoques aproximados para el algoritmos Fuzzy kNN en big data.

En este trabajo se propone una variación aproximada del algoritmo Fuzzy kNN desarrollado en Spark. Para aliviar el cuello de botella de la primera etapa del algoritmo Fuzzy kNN, se estudiarán dos enfoques: local y global. El enfoque local consiste en dividir el conjunto de datos en diferentes partes y calcular el grado de pertenencia a clase internamente en cada partición (operación map), sin considerar otras particiones. El enfoque global está basado en el modelo HS. Éste genera un árbol con las instancias del conjunto de entrenamiento y lo distribuye entre todos los nodos de cómputo, considerando todas las instancias para el cálculo del grado de pertenencia. La segunda etapa es responsable de la clasificación y común para las dos propuestas. En ésta, el esquema de trabajo es igual a la versión global de cálculo de pertenencia, pero considera la pertenencia previamente calculada clase para predecir. Para comprobar el rendimiento de este modelo, los experimentos realizados se han llevado a cabo en 4 conjuntos de datos con hasta 11 millones de instancias. El estudio experimental analiza la precisión y tiempo de ejecución realizando una comparativa con otros algoritmos de la literatura.

El documento está estructurado de la siguiente manera. La

sección II introduce el estado del arte en los algoritmos Fuzzy kNN y Hybrid Spill-Tree. La sección III detalla la propuesta aproximada del algoritmo Fuzzy kNN. El estudio experimental se describe en la Sección IV. La sección V concluye el documento y esboza el trabajo futuro.

## II. PRELIMINARES

Esta sección proporciona el conocimiento básico del algoritmo Fuzzy kNN (Sección II-A), el Hybrid Spill-Tree (Sección II-B) y las tecnologías big data utilizadas (Sección II-C).

### II-A. $k$ vecinos más cercanos difuso y su complejidad

El algoritmo Fuzzy kNN [4] se propone como una mejora del algoritmo kNN, llegando a mejorarlo en términos de precisión para la mayoría de los problemas de clasificación. Necesita una etapa de pre-cómputo en el conjunto de entrenamiento, que calcula el grado de pertenencia a la clase. Posteriormente, calcula kNN para cada instancia no vista y decide la clase predicha con el grado de pertenencia. Una notación formal para el algoritmo Fuzzy kNN es la siguiente:

Sea  $CE$  un Conjunto de Entrenamiento y  $CP$  un Conjunto de Prueba, compuestos de  $\mathbf{n}$  y  $\mathbf{t}$  instancias respectivamente. Cada instancia  $\mathbf{x}_i$  es un vector  $(\mathbf{x}_{i1}, \mathbf{x}_{i2}, \mathbf{x}_{i3}, \dots, \mathbf{x}_{ij})$ , donde  $\mathbf{x}_{ij}$  es el valor de la  $i$ -ésima instancia y  $j$ -ésima característica. Para cada instancia de  $CE$  se conoce su clase  $\omega$ . Sin embargo, para las instancias de  $CP$  la clase es desconocida.

Fuzzy kNN posee dos etapas: cálculo de pertenencia y clasificación. La primera etapa calcula los  $k$  vecinos más cercanos para cada instancia del  $CE$ , manteniendo un esquema *leave-one-out* seleccionando las  $k$  instancias con una distancia menor. Finalmente, calcula el grado de pertenencia de acuerdo a la Ecuación 1. El resultado de la primera etapa será  $CE$  modificando la etiqueta de clase  $\omega$ , por un vector de pertenencia a cada clase  $(\omega_1, \omega_2, \dots, \omega_l)$  donde  $l$  es el número de clases. Este nuevo conjunto se llamará Conjunto de Entrenamiento Difuso,  $CED$ .

$$u_j(x) = \begin{cases} 0,51 + (n_j/k_{pert}) \cdot 0,49 & \text{if } j = i \\ (n_j/k_{pert}) \cdot 0,49 & \text{if } j \neq i \end{cases} \quad (1)$$

La etapa de clasificación calcula para cada instancia de  $CP$  sus kNN como se describe en la primera etapa, para cada instancias de  $CP$  en el  $CED$  y se obtiene el grado de pertenencia a clase. Posteriormente, obtiene la clase resultante de acuerdo a la Ecuación 2.

$$u_i(x) = \frac{\sum_{j=1}^K u_{ij}(1/|x - x_j|^{2/(m-1)})}{\sum_{j=1}^K (1/|x - x_j|^{2/(m-1)})} \quad (2)$$

La etapa extra respecto a kNN y el aumento de la complejidad computacional generan dos problemas big data:

- Tiempo de ejecución: La complejidad de calcular kNN para una instancia es  $\mathcal{O}(n \cdot c)$ , donde  $n$  es el número de instancias de  $CE$  y  $c$  el número de características. Para más de un vecino, aumenta a  $\mathcal{O}(n \cdot$

$\log(N))$ . Además, Fuzzy kNN tiene una etapa extra de cómputo para el cálculo de grado de pertenencia.

- Consumo de memoria: Para acelerar el cálculo, se requiere disponer de los conjuntos  $CE$  y  $CP$  almacenados en memoria principal. Cuando ambos conjuntos son grandes, es fácil exceder la memoria principal disponible.

Para aliviar estas dificultades, trabajamos en el diseño de un modelo aproximado basado en Hybrid Spill-Tree desarrollado bajo las tecnologías big data de MapReduce y Spark.

### II-B. Hybrid Spill-Tree

El algoritmo Hybrid Spill-Tree ( $HS$ ) [9] es una propuesta aproximada para calcular el algoritmo kNN de forma distribuida.  $HS$  se compone de dos estructuras: Metric-Tree y Spill-Tree. La estructura de datos Metric-Tree ( $MT$ ) organiza el conjunto de datos en una jerarquía espacial. Es un árbol binario cuya raíz contiene todos los elementos, y donde cada hijo representa un subconjunto de elementos. La Figura 1 ilustra como dividir los elementos entre los dos hijos, seleccionando cada hijo como las instancias más lejanas posibles (representados por  $\odot$ ). Los nodos hijos de un  $MT$  no contienen instancias repetidas (representadas por  $+$ ). El árbol tendrá una profundidad de  $\mathcal{O}(\log(N))$ . Para realizar la búsqueda de la instancia más cercana, se conserva al candidato con menor distancia  $C$  y su distancia  $d$ . Si la distancia a una rama es superior a  $d$ , la poda y continúa la búsqueda. Una vez no existe una rama del árbol con distancia menor que  $d$ , se finaliza la búsqueda y se devuelve  $C$  y  $d$ . Sin embargo, invierte tiempo y cómputo en asegurar que  $C$  es el más cercano, volviendo atrás en el árbol si fuese necesario. Con el objetivo de reducir el tiempo de búsqueda emerge Spill-Tree.

La estructura de datos Spill-Tree ( $SP$ ) es una variación de  $MT$ . La diferencia principal consiste en permitir instancias compartidas entre los nodos hijos. La Figura 1 presenta cómo se dividen los datos con el mismo procedimiento que  $MT$ , permitiendo un conjunto de instancias duplicadas en los nodos hijos. El área de solapamiento es dependiente del parámetro  $\tau$ . Cuando  $\tau$  es 0, no se comparten instancias, sería un  $MT$ . Si  $\tau$  es demasiado alto, el solapamiento es alto y la profundidad del árbol tiende a infinito.  $SP$  reduce los tiempos de búsqueda respecto a  $MT$  sacrificando la *vuelta atrás* en el árbol para comprobar que  $C$  es el más cercano. Debido al solapamiento entre hijos, la instancia que encuentra, aunque aproximada, es muy representativa del problema.

$HS$  aparece con el objetivo de obtener un balance entre precisión y tiempo de ejecución. Para ello, fusiona los modelos  $MT$  y  $SP$ . Para construir la estructura híbrida de  $HS$ , se construye un  $SP$ , y si el número de instancias en el área de solapamiento es menor que el Umbral de Equilibrio ( $UE$ ), se mantiene como  $SP$ . Si las instancias repetidas superan el  $UE$ , se reconstruye como  $MT$ . Para calcular kNN sobre esta estructura, se realizará *vuelta atrás* para asegurar el más cercano si la rama es  $MT$ , mientras que los nodos  $SP$  no harán esta comprobación. Destacar la implementación

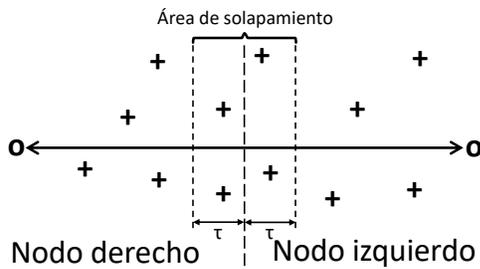


Figura 1: Construcción de Metric-Tree y Spill-Tree

disponible en el repositorio de software libre spark-package<sup>1</sup>, que es el punto de partida en la etapa de desarrollo del presente trabajo.

### II-C. Paradigma de programación MapReduce: Spark

Para el desarrollo del algoritmo propuesto en este trabajo se utilizará el paradigma de programación MapReduce [10]. MapReduce tiene como objetivo procesar grandes conjuntos de datos a través de la distribución del almacenamiento de datos y ejecución a través de un conjunto de máquinas.

La implementación de MapReduce seleccionada es Apache Spark [11]. Spark paraleliza el cálculo de forma transparente a través de una estructura de datos distribuidos llamada *Resilient Distributed Datasets* (RDD). Los RDDs permiten persistir y reutilizar estructuras de datos almacenadas en memoria principal. Adicionalmente, Spark fue desarrollado para cooperar con el sistema de archivos distribuidos de Hadoop<sup>2</sup> (Hadoop Distributed File System - HDFS). Con esta configuración, se puede aprovechar la división de instancias, la tolerancia a fallos y la comunicación de trabajos que proporciona Spark.

Spark incluye una librería de aprendizaje automático llamada MLlib<sup>3</sup>. Dispone de multitud de algoritmos de aprendizaje automático y técnicas estadísticas de diferentes áreas como clasificación, regresión o preprocesamiento de datos.

## III. FUZZY KNN ACELERADO PARA BIG DATA

En esta sección se presenta una propuesta aproximada y distribuida del algoritmo Fuzzy kNN basado en el método HS para tratar problemas big data implementado en Spark. La presente propuesta tiene las mismas dos etapas que el modelo Fuzzy kNN: grado de pertenencia a clase (Sección III-A) y clasificación (Sección III-B).

### III-A. Etapa de cálculo de grado de pertenencia a clase

Esta sección explica el flujo de trabajo de dos enfoques aproximados para calcular el grado de pertenencia a clase: Local basado en kNN (Sección III-A1) y global basado en HS (Sección III-A2). El resultado de ambos enfoques es modificar la etiqueta de clase del Conjunto de Entrenamiento ( $CE$ ) por un vector de pertenencia a clase, formando el Conjunto de Entrenamiento Difuso ( $CED$ )

<sup>1</sup>Hybrid Spill-Tree. <https://spark-packages.org/package/saurfang/spark-knn>

<sup>2</sup>Apache Hadoop. Web: <http://hadoop.apache.org/>

<sup>3</sup>Machine Learning Library for Spark. Web: <http://spark.apache.org/mllib/>

### Algorithm 1 Etapa de cálculo de grado de pertenencia - Local

---

**Require:**  $CE, k, \#Maps$

- 1:  $CEP \leftarrow \text{repartition}(CE, \#Maps)$
- 2:  $CEPD \leftarrow \text{mapPartition}(\text{calcularPertenencia}(CEP, k))$
- 3:  $CED \leftarrow \text{unir}(CEPD)$
- 4: **return**  $CED$
- 5: **COMIENZA**  $\text{calcularPertenencia}$
- 6: **for**  $y: CEP_i$  **do**
- 7:  $Vecinos_y \leftarrow \text{calcularkNNLocal}(\text{modelo}, k, y)$
- 8:  $pertenencia_y \leftarrow \text{calcularPertenencia}(Vecinos_y)$
- 9:  $CEPD \leftarrow \text{unir}(y, pertenencia_y)$
- 10: **end for**
- 11: **return**  $CEPD$
- 12: **FIN**  $\text{calcularPertenencia}$

---

### Algorithm 2 Etapa de cálculo de grado de pertenencia - Global

---

**Require:**  $CE, k$

- 1:  $muestras \leftarrow \text{muestrear}(CE, 0, 2\%)$
- 2:  $arbolSuperior \leftarrow \text{construirMT}(muestras)$
- 3:  $\tau \leftarrow \text{estimarTau}(TopTree)$
- 4:  $arbol \leftarrow \text{repartir}(CE, arbolSuperior, \tau, UE = 70\%)$
- 5:  $modelo \leftarrow (\text{difundir}(arbolSuperior), arbol)$
- 6: **for**  $y: CE$  **do**
- 7:  $Vecinos_y \leftarrow \text{calcularkNN}(\text{modelo}, k, y)$
- 8:  $pertenencia_y \leftarrow \text{calcularPertenencia}(Vecinos_y)$
- 9:  $resultado_y \leftarrow \text{unir}(y, pertenencia_y)$
- 10: **end for**
- 11: **return**  $resultado$

---

*III-A1. Enfoque local:* El enfoque local conjuntamente con la etapa de clasificación recibe el nombre *Local Hybrid Spill-Tree Fuzzy kNN* (L-HSFkNN). El Algoritmo 1 muestra los pasos y operaciones en Spark para el cálculo del grado de pertenencia. Comienza leyendo el  $CE$  de HDFS y es dividido en  $\#Maps$  partes. Posteriormente, utiliza una operación *mapPartition* de Spark para calcular de forma distribuida el grado de pertenencia a clase para cada partición  $CEP_i$ . Para cada instancia  $y$  de cada partición  $CEP_i$ , calcula kNN y finalmente obtiene el grado de pertenencia aplicando la Ecuación 1. Una vez obtenida la pertenencia para cada partición, se agrupan los resultados y forman el  $CED$ , que será la entrada de la etapa de clasificación.

*III-A2. Enfoque global basado en HS:* El enfoque global sumado a la etapa de clasificación recibe el nombre *Global Approximate Hybrid Spill-Tree Fuzzy kNN* (GA-HSFkNN). El Algoritmo 1 muestra los pasos y operaciones en Spark para el cálculo del grado de pertenencia.

El algoritmo 2 muestra los pasos de la etapa de cálculo de pertenencia. Las líneas 1-5 corresponden a la etapa de ajuste del modelo, y las restantes al cálculo del grado de pertenencia.

La etapa de ajuste del modelo comienza leyendo el  $CE$  de HDFS. En primer lugar, toma un submuestreo aleatorio para construir un  $MT$  como se describe en la Sección II-B (Los autores recomiendan un 0,2%). Este  $MT$  recibe el nombre de árbol superior ( $AS$ ) y es usado para estimar el valor del parámetro  $\tau$  y particionar todo el  $CE$ . La estimación de  $\tau$  es la distancia media entre las instancias. Para acelerar este cálculo, se realiza con las instancias del  $AS$ .

El siguiente paso es repartir el  $CE$ . Para ello, a partir

**Algorithm 3** Calcular kNN

---

```
Require: modelo, k, x
1: Indices  $\leftarrow$  x.flatMap ( buscaIndices(modelo.arbol) )
2: Vecinos  $\leftarrow$  consulta(modelo.arbol, Indices, k)
3: return Vecinos
4:
5: COMIENZA buscaIndices
6: distIzq  $\leftarrow$  nodoIzq.dist(x)
7: distDch  $\leftarrow$  nodoDch.dist(x)
8: if nodo! = HOJA then
9:   if distIzq < distDch then
10:     buscaIndices(nodoIzq, ID)
11:   else
12:     buscaIndices(nodoDch, ID + hijoIzq)
13:   end if
14: else
15:   return Indices
16: end if
17: FIN buscaIndices
```

---

del *AS* se distribuyen las instancias en el espacio. El valor de  $\tau$  define el área de solapamiento. Comienza construyendo un *SP*, y comprueba si el número de instancias en el área de solapamiento es menor que el 70%. En otro caso, se reconstruye un *MT*. Al realizar la búsqueda, aquellas ramas *SP* realizan una búsqueda más rápida al no tener que volver atrás en el árbol. Sin embargo, las construidas como *MT* realizan *vuelta atrás* para asegurar el más cercano. La etapa de construcción del modelo termina distribuyendo el *AS* y el árbol asociado al *CE*.

La etapa de cálculo de grado de pertenencia se muestra en las líneas 6-10. Para cada instancia de *CE*, se calcula kNN siguiendo el modelo generado. El Algoritmo 3 describe como se realiza la búsqueda con operaciones nativas de Spark. Mediante una operación flatMap, se computan y obtienen los índices de las instancias más cercanas del *CE*. Para ello, se calcula la distancia hasta el nodo derecho e izquierdo, y continúa por el nodo con una distancia menor. Cuando alcanza un nodo hoja, devuelve el índice de la instancia seleccionada.

Dados los vecinos, se calcula el grado de pertenencia siguiendo la Ecuación 1. (Línea 8). El resultado de esta fase es el *CED*, pasando a ser la entrada de la etapa de clasificación.

### III-B. Clasificación con Hybrid Spill-Tree

Esta sección describe la etapa de clasificación, la cual recibe como entrada el *CED* calculado en la etapa previa. La etapa de clasificación está basada en *HS* y sigue la misma estructura que la aproximación global de la primera etapa (Sección III-A2). Tiene dos fases diferenciadas: creación del modelo y clasificación. La primera construye el árbol y divide las instancias entre los nodos de cómputo. La segunda busca las *k* instancias más cercanas de *CED* calculado en la primera etapa, y devuelve como salida la clase predicha de acuerdo al vector de grado de pertenencia.

El Algoritmo 4 muestra los pasos de la etapa de clasificación. Se especificarán las diferencias con respecto a la sección III-A2, ya que el esquema principal es el mismo y sólo se ven afectados pequeños detalles de la estructura de datos.

**Algorithm 4** Etapa de clasificación

---

```
Require: CED, CP, k
1: muestreas  $\leftarrow$  muestrear(CED,0,2%)
2: arbolSuperior  $\leftarrow$  construirMT(muestreas)
3:  $\tau$   $\leftarrow$  estimarTau(TopTree)
4: arbol  $\leftarrow$  repartir(CED, arbolSuperior,  $\tau$ , UE = 70%)
5: modelo  $\leftarrow$  (difundir(arbolSuperior),arbol)
6: for y: CE do
7:   Vecinosy  $\leftarrow$  calcularFuzzykNN (modelo, k, y)
8:   predicciony  $\leftarrow$  calcularPredicción (Vecinosy)
9: end for
10: return predicciony
```

---

La primera diferencia se encuentra en los conjuntos de datos de entrada. En este caso, se utilizarán *CED* y *CP*. La fase de ajuste del modelo no se ve afectada pues no se modifican las características, manteniendo las distancias de las instancias. Así, se construye el modelo con la misma metodología.

El cálculo de Fuzzy kNN se hace de la misma manera, con la diferencia de que en lugar de devolver la etiqueta de clase para cada vecino, se devuelve el vector de grado de pertenencia a la clase (Línea 7). La línea 8 calcula la clase predicha aplicando la Ecuación 2. El resultado final es la clase prevista para cada instancia de *CP*.

## IV. ESTUDIO EXPERIMENTAL

En esta sección se presentan las cuestiones planteadas en el estudio experimental. La Sección IV-A presenta los algoritmos de comparación utilizados para la experimentación. La Sección IV-B determina el marco de los experimentos. Finalmente, la Sección IV-C expone y analiza los resultados obtenidos.

### IV-A. Algoritmos de comparación

Esta sección expone los algoritmos de comparación utilizados en los experimentos y sus acrónimos. Se compara con otras propuestas de Fuzzy kNN y sus análogos no *Fuzzy* siguiendo dos enfoques: local y global. El enfoque local divide las instancias y los distribuye entre los nodos de cómputo, ejecutando de forma independiente en cada partición, obteniendo resultados aproximados. El enfoque global si considera todas las instancias, aunque realice el cómputo de forma distribuida y a su vez presenta dos posibilidades: exacto y aproximado. El exacto invierte cálculo en asegurar que el resultado es igual que la variante secuencial. El aproximado, no asegura el mismo resultado acelerando el tiempo de ejecución.

Algoritmos utilizados en la experimentación para realizar la comparativa:

- *Global Exact Fuzzy kNN (GE-FkNN)* [8]: modelo exacto del algoritmo Fuzzy kNN para abordar problemas big data, obteniendo los mismos resultados que el Fuzzy kNN original. Sus dos etapas son globales y exactas.
- *Local Fuzzy kNN (L-FkNN)*: propuesta desarrollada del algoritmo Fuzzy kNN. La primera etapa es la descrita en la Sección III-A1 y su segunda etapa sería global y exacta, idéntica a la de GE-FkNN.



- *k Nearest Neighbor - Iterative Spark (kNN-IS)* [5]: propuesta exacta de kNN para abordar problemas big data, obteniendo los mismos resultados que el kNN original.
- *Hybrid Spill-Tree kNN (HS-kNN)* [9]: propuesta aproximada de kNN para big data. Aunque aproximada, considera todas las instancias en la búsqueda.

#### IV-B. Marco experimental

Para el estudio experimental, se han seleccionado cuatro conjuntos de datos de un elevado número de instancias. El conjunto de datos ECBDL14 se extrae de la competición [12]. A pesar de que tiene una relación de desbalanceo superior a 45, hemos seleccionado este conjunto de datos por su número relativamente alto de características. Sin embargo, en este documento no abordamos el problema de la clasificación desequilibrada, por lo que se ha submuestreado dejándolo en una relación de desbalanceo de dos. Los otros tres conjuntos han sido extraídos del repositorio UCI [13]. La Tabla I presenta el número de instancias, características y clases ( $\#\omega$ ). Se seguirá el esquema de validación cruzada en 5 particiones.

Tabla I: Descripción de los conjuntos de datos

Conjunto de datos	#Instancias	# Características	$\#\omega$
Poker	1.025.010	10	10
ECBDL14	2.063.187	631	2
Susy	5.000.000	18	2
Higgs	11.000.000	28	2

Se tendrán en cuenta las siguientes medidas para evaluar el rendimiento de la técnica propuesta:

- *Precisión*: Contabiliza el número de clasificaciones correctas en relación con el número total de instancias.
- *Tiempo de ejecución*: Tiempo consumido considerando lecturas y comunicaciones por red de Spark.

El parámetro más conocido para el algoritmo original Fuzzy kNN es el número de vecinos ( $k$ ).  $k$  podría ser diferente en cada etapa, pero mantendremos ambos iguales por simplicidad. En nuestros experimentos, el parámetro  $k$  está ajustado a 3, 5 y 7. Se necesita un parámetro adicional debido a su comportamiento distribuido. Este es el número de particiones del conjunto de entrenamiento. Para expresar la componente distribuida, se utilizará el máximo posible para la configuración del cluster, 256 operaciones maps/particiones.

Los algoritmos basados en HS tienen dos parámetros adicionales: el número de instancias para construir el árbol principal  $AP$  y el umbral de equilibrio  $UE$ . Los valores recomendados por los autores son  $AP$  igual al 0,2% y  $UE$  igual al 70%.

Todos los experimentos se han realizado en un cluster compuesto por 14 nodos de cálculo gestionados por un nodo maestro. Todos los nodos tienen la misma configuración. 2 procesadores Intel Xeon CPU E5-2620, 6 núcleos (12 hilos) por procesador, 2 GHz y 64 GB de RAM. Red Infiniband 40Gb/s. Con la configuración actual, se disponen de 256 tareas map como máximo. La versión de Spark es 2.2.1.

#### IV-C. Resultados obtenidos y análisis

Esta sección presenta una comparativa de los modelos propuestos y los detallados en la Sección IV-A, analizando el

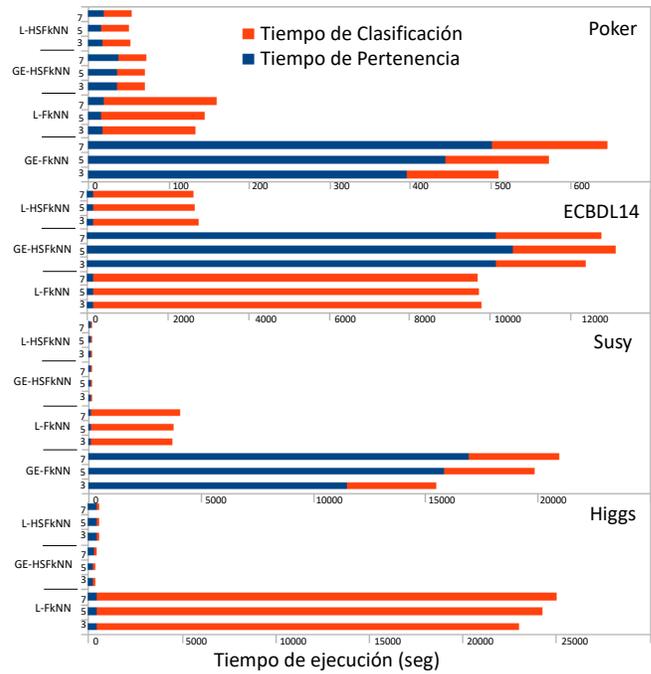


Figura 2: Tiempo de ejecución para cada conjunto y algoritmo

tiempo de ejecución y la precisión de cada uno de ellos. Para realizar un análisis detallado de los algoritmos, se utilizarán los 4 conjuntos de datos expuestos en la Tabla I. La Sección IV-C1 presenta el tiempo de ejecución y precisión. La Sección IV-C2 compara los algoritmos propuestos con otros algoritmos de la literatura.

*IV-C1. Estudio de tiempo y precisión:* Esta sección presenta y estudia el tiempo de ejecución y precisión obtenida para los 4 conjuntos de datos y los diferentes algoritmos.

La Tabla II muestra una comparación de precisión entre los algoritmos en relación al número de vecinos ( $k$ ) y para todos los conjuntos de datos.

Tabla II: Comparativa entre algoritmos - Precisión

Algoritmo	$k$	Poker	ECBDL14	Susy	Higgs
GE-FkNN	3	0,5257	-	0,7301	-
	5	0,5316	-	0,7306	-
	7	0,5338	-	0,7268	-
L-FkNN	3	0,5218	0,7636	0,7178	0,5936
	5	0,5243	0,7492	0,7190	0,5953
	7	0,5243	0,7423	0,7179	0,5959
GA-HSFkNN	3	0,5233	<b>0,8051</b>	0,7302	0,5968
	5	0,5371	0,8050	0,7457	0,6081
	7	0,5459	0,8014	<b>0,7510</b>	0,6162
L-HSFkNN	3	0,5324	0,8035	0,7320	0,6038
	5	0,5432	0,8027	0,7438	0,6139
	3	<b>0,5487</b>	0,7969	0,7471	<b>0,6198</b>

La Figura 2 muestra el tiempo de la etapa de cálculo de pertenencia y el tiempo de la etapa de clasificación en segundos, para cada conjunto de datos, algoritmo y los valores de  $k$  igual a 3, 5 y 7.

De acuerdo con la tabla y figura presentadas, se observa:

Tabla III: Comparativa contra propuestas kNN

Conjunto de datos	Algoritmo	$k$	Tiempo Total	Precisión
Poker	kNN-IS	3	113,2370	0,4758
		5	123,8311	0,4952
		7	136,5830	0,4937
	HS-kNN	3	32,9661	0,5201
		5	33,4674	0,5305
		7	35,5575	0,5369
	GA-HSFkNN	7	72,1978	0,5459
		L-HSFkNN	7	54,3435
	ECBDL14	kNN-IS	3	27121,0583
5			28673,7015	0,7797
7			28918,2992	0,7683
HS-kNN		3	3151,6242	0,8020
		5	2608,1722	0,8017
		7	2691,5595	0,7986
GA-HSFkNN		3	12413,8265	<b>0,8051</b>
		L-HSFkNN	3	2787,1230
Susy		kNN-IS	3	2615,0150
	5		2273,6377	0,6784
	7		2372,4100	0,6861
	HS-kNN	3	128,1860	0,7223
		5	131,0210	0,7360
		7	133,2428	0,7431
	GA-HSFkNN	7	133,2568	<b>0,7510</b>
		L-HSFkNN	7	146,2076
	Higgs	kNN-IS	3	10262,9178
5			13446,0519	0,5458
7			14285,6442	0,5559
HS-kNN		3	641,4434	0,5885
		5	651,1573	0,5936
		7	664,9204	0,5981
GA-HSFkNN		7	429,3507	0,6162
		L-HSFkNN	7	608,2571

- El valor de  $k$  no afecta significativamente a los tiempos de ejecución en ninguna de las etapas.
- El algoritmo GE-FkNN encuentra su límite de escalabilidad en su primera etapa, no llegando a ejecutar para los datasets ECBDL14 y Higgs.
- Centrándonos en los tiempos de ejecución, el modelo L-FkNN escala mejor en la primera etapa y se ve menos afectado por el número de características. El algoritmo GA-HSFkNN consigue mejores tiempos en la etapa de clasificación. Así, los mejores tiempos de ejecución son obtenidos por el algoritmo L-HSFkNN, que toma la primera etapa del algoritmo L-FkNN y la etapa de clasificación de GA-HSFkNN.
- En precisión los ganadores son GA-HSFkNN y L-HSFkNN con diferencias poco significativas. Teniendo en cuenta que los tiempos de ejecución totales son menores para L-HSFkNN, es nuestra propuesta más escalable y de mayor calidad.

*IV-C2. Comparativa con versiones kNN big data:* En esta sección se comparan los modelos basados en conjuntos difuso con las versiones clásicas de kNN para big data. La Tabla III muestra una comparativa entre el mejor resultado obtenido por los dos algoritmos propuestos y las dos alternativas no *Fuzzy*, explorando los mismos valores de  $k$ . Se muestra para cada conjunto de datos y algoritmo, el tiempo total de ejecución y el valor de  $k$  utilizado asociado a la precisión obtenida.

De acuerdo con la tabla presentada, se puede observar que los mejores resultados los obtienen las versiones *Fuzzy*.

Además, kNN-IS obtiene resultados significativamente peores que los demás algoritmos. Aunque HS-kNN mejora respecto al algoritmo kNN-IS, siempre queda por debajo de los modelos propuestos, sin verse incrementado en exceso el tiempo de ejecución debido a la optimización realizada en la etapa de clasificación del algoritmo GA-HSFkNN.

## V. CONCLUSIONES Y TRABAJO FUTURO

En esta contribución se ha propuesto un enfoque MapReduce para acelerar el algoritmo Fuzzy kNN en problemas Big data. Gracias al diseño realizado y al uso de tecnologías big data, se consigue ejecutar con conjuntos de datos muy grandes, que de otra forma sería inviable. Los experimentos realizados comparan la propuesta con otros enfoques de comportamiento exacto y aproximado para conseguir un equilibrio entre eficiencia y precisión. Asimismo, se ha comparado con las versiones no *Fuzzy* para estudiar la mejora del modelo propuesto. El algoritmo L-HSFkNN demuestra una escalabilidad muy elevada, así como resultados en precisión de alta calidad. Como trabajo futuro, se plantea adaptar el modelo desarrollado a otros problemas de minería de datos como regresión, o aprendizaje semi-supervisado.

## AGRADECIMIENTOS

Este trabajo se ha sustentado por el proyecto de investigación TIN2017-89517-P. J. Mailló disfruta de una beca FPU del Ministerio de Educación de España.

## REFERENCIAS

- T. M. Cover, P. E. Hart, Nearest neighbor pattern classification, IEEE Transactions on Information Theory 13 (1) (1967) 21–27.
- X. Wu, V. Kumar (Eds.), The Top Ten Algorithms in Data Mining, Chapman & Hall/CRC Data Mining and Knowledge Discovery, 2009.
- J. Derrac, S. García, F. Herrera, Fuzzy nearest neighbor algorithms: Taxonomy, experimental analysis and prospects, Information Sciences 260 (2014) 98 – 119.
- J. M. Keller, M. R. Gray, J. A. Givens, A fuzzy k-nearest neighbor algorithm, IEEE Transactions on Systems, Man, and Cybernetics SMC-15 (4) (1985) 580–585.
- J. K. Uhlmann, S. Ramírez, I. Triguero, F. Herrera, kNN-IS: an iterative spark-based design of the k-Nearest Neighbors classifier for big data, Knowledge-Based Systems 117 (Supplement C) (2017) 3 – 15, volume, Variety and Velocity in Data Science.
- J. K. Uhlmann, Satisfying general proximity / similarity queries with metric trees, Information Processing Letters 40 (4) (1991) 175 – 179.
- T. Liu, A. W. Moore, K. Yang, A. G. Gray, An investigation of practical approximate nearest neighbor algorithms, in: Advances in neural information processing systems, 2005, pp. 825–832.
- J. Mailló, J. Luengo, S. García, F. Herrera, I. Triguero, Exact fuzzy k-nearest neighbor classification for big datasets, in: 2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), 2017, pp. 1–6.
- T. Liu, C. J. Rosenberg, H. A. Rowley, Performing a parallel nearest-neighbor matching operation using a parallel hybrid spill tree, uS Patent 7,475,071 (Jan. 6 2009).
- J. Dean, S. Ghemawat, Map reduce: A flexible data processing tool, Communications of the ACM 53 (1) (2010) 72–77.
- M. Zaharia, M. Chowdhury, T. Das, A. Dave, J. Ma, M. McCauley, M. J. Franklin, S. Shenker, I. Stoica, Resilient distributed datasets: A fault-tolerant abstraction for in-memory cluster computing, in: Proceedings of the 9th USENIX conference on Networked Systems Design and Implementation, 2012, pp. 1–14.
- ECBDL14 dataset: Protein structure prediction and contact map for the ECBDL2014 big data competition (2014). URL <http://cruncher.ncl.ac.uk/bdcomp/>
- M. Lichman, UCI machine learning repository (2013). URL <http://archive.ics.uci.edu/ml>



# Aplicando la transformada integral de la probabilidad para reducir la complejidad de los árboles de decisión difusos multi-vía en problemas de clasificación Big Data

Mikel Elcano<sup>\*†‡</sup>, Mikel Uriz<sup>\*†</sup>, Humberto Bustince<sup>\*†‡</sup>, Mikel Galar<sup>\*†‡</sup>

<sup>\*</sup>Departamento de Estadística, Informática y Matemáticas, Universidad Pública de Navarra, 31006 Pamplona, España

<sup>†</sup>GIARA, Navarrabiomed, Complejo Hospitalario de Navarra (CHN), Universidad Pública de Navarra (UPNA), IdiSNA Irunlarrea 3, 31008 Pamplona, España

<sup>‡</sup>Institute of Smart Cities, Universidad Pública de Navarra, 31006 Pamplona, España

Emails: {mikel.elcano, mikelxabier.uriz, bustince, mikel.galar}@unavarra.es

**Resumen**—Presentamos un nuevo método de particionamiento difuso distribuido para reducir la complejidad de los árboles de decisión difusos multi-vía en problemas de clasificación Big Data. El algoritmo propuesto construye un número fijo de conjuntos difusos para todas las variables y ajusta su forma y posición a la distribución real de los datos de entrenamiento. Para ello se aplica un proceso compuesto por dos fases: 1) transformación de la distribución original en una distribución uniforme estándar mediante la transformada integral de la probabilidad. Dado que generalmente la distribución original se desconoce, se calcula una aproximación de la función de distribución acumulada extrayendo los  $q$ -cuantiles del conjunto de entrenamiento; 2) construcción de una partición difusa de Ruspini en el espacio de características transformado empleando un número fijo de funciones de pertenencia triangulares uniformemente distribuidas. A pesar de realizar una transformación sobre los datos originales, la definición de los conjuntos difusos en el espacio original se puede recuperar aplicando la función cuantil. Los resultados experimentales revelan que el método de particionamiento propuesto permite mantener la precisión del árbol de decisión difuso multi-vía del estado del arte FMDT empleando hasta 6 millones menos de hojas.

**Index Terms**—Árboles de Decisión Difusos; Transformada Integral de la Probabilidad; Función Cuantil; MapReduce; Apache Spark; Big Data

## I. INTRODUCCIÓN

Los árboles de decisión (ADs) [1] son uno de los algoritmos de aprendizaje automático más populares, habiendo sido aplicados en una gran variedad de problemas como las finanzas [2], la clasificación de imágenes [3], la bioinformática [4], o la medicina [5]. La principal característica de los ADs es la habilidad para explicar el razonamiento de sus predicciones mediante grafos en forma de árboles. Cada nodo es una pregunta o test en un atributo determinado (por ejemplo, ¿ $x > 0,5$ ?), cada rama representa la respuesta o el resultado del test, y los nodos terminales (hojas) contienen la decisión final. Generalmente los árboles se construyen aplicando una estrategia *top-down* llamada *particionamiento recursivo* [1], en donde los datos de entrada se dividen recursivamente en

dos o más sub-espacios que aumentan la homogeneidad de las distribución de las clases.

La lógica difusa [6] ha mostrado ser una forma efectiva para mejorar el rendimiento de clasificación de los algoritmos de aprendizaje automático cuando se trabaja con datos imprecisos que generan incertidumbre [7], [8], incluyendo los árboles de decisión difusos (ADDs). Sin embargo, en entornos Big Data los excesivos requerimientos de tiempo y espacio de los ADDs afectan seriamente la escalabilidad de estos algoritmos. Segatori et al. propusieron una solución MapReduce que consiste en un nuevo método de particionamiento difuso y en un algoritmo de aprendizaje de ADD distribuido [9]. El discretizador genera una partición difusa fuerte y triangular para cada atributo continuo basándose en la entropía difusa, las cuales son empleadas posteriormente para construir el árbol. Los autores propusieron dos versiones de ADD que difieren en la estrategia de particionamiento recursivo: el ADD binario (o bi-vía) (FBDT) y el ADD multi-vía (FMDT). El ADD binario divide el espacio del atributo en dos sub-espacios (nodos hijo), mientras que el ADD multi-vía puede generar más de dos sub-espacios. A pesar de que la solución propuesta por Segatori et al. consigue buenos resultados en términos de precisión, normalmente los árboles construidos por este algoritmo están compuestos por miles e incluso millones de hojas, por lo que la complejidad del modelo es generalmente elevada.

En este trabajo presentamos un nuevo método de particionamiento difuso que reduce la complejidad de los árboles construidos por FMDT en términos de número de conjuntos difusos empleado por variable y número de hojas. El algoritmo propuesto aplica la *transformada integral de la probabilidad* [10] para ajustar un número fijo de conjuntos difusos a la distribución real del conjunto de entrenamiento. Esta transformación permite convertir las variables del conjunto de entrenamiento en variables aleatorias uniformes independientemente de su distribución original. Posteriormente, se construyen las particiones difusas de Ruspini [11] en el nuevo espacio transformado empleando funciones de pertenencia

triangulares uniformemente distribuidas. Los conjuntos difusos resultantes se utilizan posteriormente por el FMDT original para construir el árbol.

Para evaluar los beneficios de nuestra propuesta, hemos llevado a cabo un estudio empírico que consiste en 4 problemas de clasificación Big Data disponibles en los repositorios de UCI [12] y OpenML<sup>1</sup>. En este estudio comparamos la precisión y la complejidad del modelo de FMDT cuando se considera el método de particionamiento difuso original y el propuesto. Los resultados experimentales muestran una reducción significativa en la complejidad del modelo cuando se aplica nuestro método.

La estructura de este trabajo es la siguiente. La Sección II repasa los conceptos básicos de los ADDs y describe brevemente la solución distribuida de Segatori et al. para construir ADDs para Big Data. En la Sección III introducimos el método de particionamiento difuso propuesto. El marco y el estudio experimental se muestran en las Secciones IV y V. Finalmente, la Sección VI presenta las conclusiones de este trabajo.

## II. PRELIMINARES: ÁRBOLES DE DECISIÓN DIFUSOS PARA BIG DATA

Los árboles de decisión (ADs) [1] son algoritmos de aprendizaje automático supervisado no-paramétricos empleados para tareas de clasificación y regresión. En este trabajo nos centramos en las tareas de clasificación, las cuales consisten en construir un modelo predictivo llamado *clasificador* que es capaz de clasificar ejemplos no etiquetados (desconocidos) en base a un conjunto de entrenamiento formado por ejemplos previamente etiquetados. Cada ejemplo  $x = (x_1, \dots, x_F)$  contenido en el conjunto de entrenamiento  $TR$  pertenece a una clase  $y \in \mathbb{C} = \{C_1, \dots, C_M\}$  (siendo  $M$  el número de clases del problema) y se caracteriza por un conjunto de  $F$  variables (también llamadas atributos o características), donde cada variable  $x_f$  puede tomar cualquier valor contenido en el conjunto  $\mathcal{F}_f$ . Por tanto, la construcción de un clasificador consiste en encontrar una función de decisión  $h : \mathcal{F}_1 \times \dots \times \mathcal{F}_F \rightarrow \mathbb{C}$  que maximice la precisión en la clasificación.

Un AD es un grafo dirigido acíclico donde cada nodo interno es un test sobre un atributo, cada rama representa el resultado del test, y cada nodo terminal (hoja) contiene la decisión final (etiqueta de la clase). Los ADs se construyen aplicando un *particionamiento recursivo* [1] del espacio de atributos. La selección del atributo considerado en el nodo de decisión está basada en métricas que miden la diferencia entre el nivel de homogeneidad de las clases contenidas en el nodo padre y en los nodos hijos. Para los atributos continuos se pueden aplicar soluciones basadas tanto en fuerza bruta como en estrategias de discretización. Las primeras comprueban todos los posibles puntos de corte en el conjunto de entrenamiento, mientras que las últimas dividen el dominio del atributo en un conjunto discreto de intervalos (también llamados *bins*). Dado que las soluciones por fuerza bruta

pueden ser computacionalmente costosas, los ADs diseñados para Big Data suelen aplicar estrategias de discretización para acelerar la ejecución del algoritmo y reducir la complejidad del modelo.

Los árboles de decisión difusos (ADDs) [7] hacen uso de la lógica difusa [6] para manejar mejor la incertidumbre y crear fronteras de decisión suaves que mejoran la precisión de la clasificación. En este caso los atributos continuos están caracterizados por particiones difusas en lugar de un conjunto discreto de intervalos. Por consiguiente, un valor de entrada determinado puede pertenecer a uno o más conjuntos difusos con un grado de pertenencia determinado y activar múltiples ramas al mismo tiempo. Las particiones difusas permiten manejar transiciones progresivas entre los intervalos adyacentes y mejorar así la precisión de las predicciones cuando se manejan datos numéricos. A la hora de clasificar un nuevo ejemplo  $x$ , se calcula el grado de activación de cada hoja. Para ello se debe calcular el grado de activación de todos los nodos internos que pertenecen a la ruta de la hoja correspondiente de la siguiente forma. Dado el nodo actual  $CN$  que considera  $x_f$  como el atributo a dividir, se calcula el grado de activación  $md^{CN}(x)$  de  $CN$  para  $x$ :

$$md^{CN}(x) = T(\mu^{CN}(x_f), md^{PN}(x)), \quad (1)$$

donde  $T$  es una T-norma,  $\mu^{CN}(x_f)$  es el grado de pertenencia de  $x_f$  al conjunto difuso asociado con el nodo  $CN$ , y  $md^{PN}(x)$  es el grado de activación del nodo padre  $PN$  para  $x$ . Posteriormente, se obtiene el grado de asociación  $AD_m^{LN}(x)$  de la clase  $C_m$  en la hoja  $LN$  para  $x$ :

$$AD_m^{LN}(x) = md^{LN}(x) \cdot w_m^{LN}, \quad (2)$$

donde  $md^{LN}(x)$  es el grado de activación de la hoja  $LN$  para  $x$  y  $w_m^{LN}$  es el peso de la clase  $C_m$  en  $LN$ . En la literatura se han propuesto diferentes definiciones para  $w_m^{LN}$  [13]. En este trabajo consideramos

$$w_m^{LN} = \frac{\sum_{x \in TR_{C_m}} md^{LN}(x)}{\sum_{x \in TR} md^{LN}(x)}, \quad (3)$$

donde  $TR_{C_m}$  es el conjunto de todos los ejemplos de entrenamiento que pertenecen a la clase  $C_m$ . Finalmente, se predice la clase de  $x$  siguiendo un determinado criterio, siendo los siguientes los más comunes:

- *Máxima activación*: se predice la clase que corresponde al máximo grado de asociación.
- *Voto ponderado*: para cada clase se calcula la suma de todos los grados de asociación correspondientes a la clase y se predice aquella que obtiene la mayor suma.

Los requerimientos de tiempo y memoria de los ADDs pueden causar serios problemas de escalabilidad cuando se tratan grandes conjuntos de datos. En este trabajo consideramos la solución distribuida propuesta por Segatori et al. en [9] para construir ADDs en Big Data, la cual consta de dos fases:

<sup>1</sup><https://www.openml.org/search?type=data>



1. *Particionamiento difuso*. Se genera una partición difusa triangular fuerte para cada atributo continuo basándose en la entropía difusa. Para ello, el algoritmo selecciona la partición difusa candidata que minimiza la entropía difusa y divide el dominio del atributo en dos subconjuntos de forma recursiva hasta que se cumple una cierta condición de parada. A pesar de que las particiones difusas construidas por este método suelen ser precisas, el alto número de conjuntos difusos que habitualmente contienen aumenta la complejidad del modelo.
2. *Aprendizaje del ADD*. Se construye un ADD aplicando una de las dos estrategias de división consideradas por los autores: binaria (FBDT), que genera dos nodos hijos, o multi-vía (FMDT), que puede generar más de dos hijos. Ambos métodos emplean la ganancia de información difusa [14] para la selección del atributo. En este trabajo nos centramos en los árboles FMDT.

### III. APLICANDO LA TRANSFORMADA INTEGRAL DE LA PROBABILIDAD PARA REDUCIR LA COMPLEJIDAD DE LOS ÁRBOLES DE DECISIÓN DIFUSOS MULTI-VÍA

En este trabajo proponemos un nuevo método de particionamiento difuso distribuido que reduce la complejidad de los ADDs generados por el algoritmo FMDT [9]. La solución propuesta reemplaza el método de particionamiento difuso original empleado por FMDT sin alterar el algoritmo de aprendizaje del ADD. Los objetivos de nuestra propuesta son los siguientes:

- Construir un número reducido de conjuntos difusos por atributo. El método original añade conjuntos difusos a la partición hasta que la ganancia de información difusa es menor que un cierto umbral, aumentando la complejidad del modelo. Nuestro método emplea un número fijo de conjuntos difusos para todos los atributos.
- Ajustar los conjuntos difusos a la distribución real de los atributos. La solución propuesta modifica tanto la forma como la posición de los conjuntos difusos para mejorar la capacidad de discriminación del modelo

Para cumplir estos objetivos proponemos un algoritmo que consiste en una fase de pre-procesamiento que resulta en un particionamiento difuso auto-adaptativo.

- Pre-procesamiento: las variables del conjunto de entrenamiento son transformadas en variables aleatorias uniformes aplicando la *transformada integral de la probabilidad* [10] descrita en el Teorema 1. Este teorema afirma que cualquier variable aleatoria continua puede ser convertida en una variable aleatoria uniforme estándar.

**Teorema 1.** Si  $X$  es una variable aleatoria continua con una función de distribución acumulada (FDA)  $F_X(x)$  y si  $Y = F_X(X)$ , entonces  $Y$  es una variable aleatoria uniforme en el intervalo  $[0,1]$ .

*Demostración.* Supongamos que  $Y = g(X)$  es una función de  $X$  donde  $g$  es derivable y estrictamente

creciente. Por tanto, su inversa  $g^{-1}$  existe únicamente. La FDA de  $Y$  se puede derivar usando

$$\begin{aligned} F_Y(y) &= Prob(Y \leq y) = Prob(X \leq g^{-1}(y)) \\ &= F_X(g^{-1}(y)) \end{aligned}$$

y su densidad viene dada por

$$\begin{aligned} f_Y(y) &= \frac{d}{dy} F_Y(y) = \frac{d}{dy} F_X(g^{-1}(y)) \\ &= f_X(g^{-1}(y)) \cdot \frac{d}{dy} g^{-1}(y). \end{aligned}$$

Este procedimiento se llama la técnica de la FDA y permite que la distribución de  $Y$  se derive de la siguiente forma:

$$\begin{aligned} F_Y(y) &= Prob(Y \leq y) = Prob(X \leq F_X^{-1}(y)) \\ &= F_X(F_X^{-1}(y)) = y \end{aligned}$$

■

Sin embargo, dado que la distribución original del conjunto de entrenamiento es desconocida, la FDA no puede ser calculada exactamente. Como solución proponemos calcular los  $q$ -cuantiles del conjunto de entrenamiento para obtener una FDA aproximada. Para ello, para cada variable, se ordenan todos los valores y se extrae cada cuantil. Si  $q$  es menor que el número de ejemplos en el conjunto de entrenamiento, el valor de la FDA para un valor dado se interpola linealmente en el intervalo  $[Q_{i-1}, Q_i]$ , siendo  $Q_i$  el primer cuantil mayor que el valor. Si el valor es menor que el primer cuantil ( $Q_1$ ) o mayor que el último cuantil ( $Q_{q-1}$ ), el valor de la FDA será 0 o 1, respectivamente. De esta forma, las variables del nuevo conjunto de datos transformado seguirán una distribución aproximadamente uniforme independientemente de su distribución original. Por supuesto, la transformación sobre el conjunto de test se realiza interpolando la FDA con los cuantiles extraídos del conjunto de entrenamiento.

- Particionamiento: se construye una partición difusa fuerte de Ruspini [11] distribuyendo uniformemente un número fijo de funciones de pertenencia triangulares a lo largo del intervalo  $[0,1]$ . Cabe destacar que la definición de cada uno de los conjuntos difusos en el espacio original puede recuperarse aplicando la función cuantil [15]. En este caso, para cada punto que define la función de pertenencia triangular, el valor correspondiente se interpolaría calculando la inversa de la función lineal empleada para calcular la FDA entre los dos cuantiles más próximos. La Figura 1 muestra un ejemplo ilustrativo de cómo se distribuyen los conjuntos difusos en el espacio original y en el transformado del atributo *jet\_1\_eta* del conjunto de datos HIGGS. Las líneas sólidas y las barras representan las funciones de pertenencia y la distribución original de las variables, respectivamente.

Nótese que ambas fases (pre-procesamiento y particionamiento) están estrechamente relacionadas. Dado que, bajo nuestro punto de vista, una partición difusa de Ruspini con

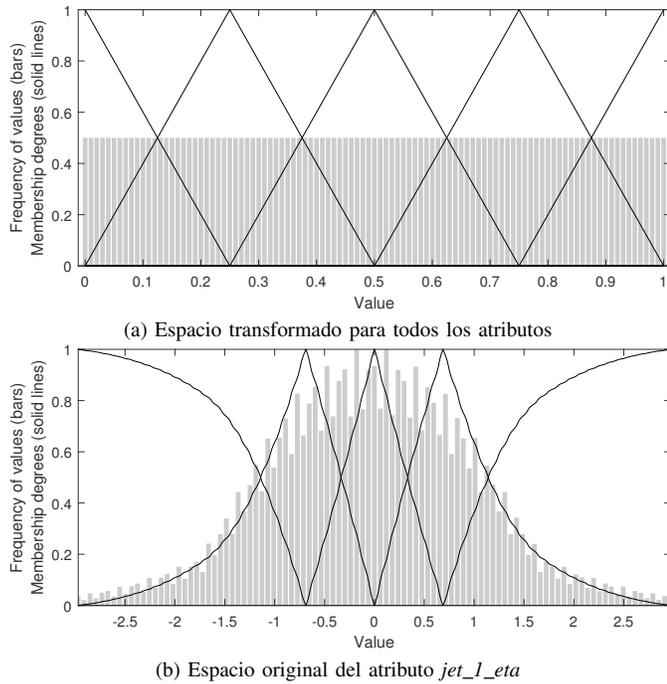


Figura 1: Conjuntos difusos construidos para *jet\_1\_eta* en HIGGS.

funciones de pertenencia uniformemente distribuidas es una buena forma de modelar una distribución uniforme, nuestra hipótesis es que si es posible transformar la distribución de cualquier atributo en una distribución uniforme y al mismo tiempo poder realizar el proceso inverso, se obtiene una partición auto-adaptada para la distribución original del atributo. El hecho más interesante es que este resultado se obtiene sin necesidad de diseñar un nuevo método de particionamiento específico. El código fuente de nuestra propuesta está escrito en Scala 2.11<sup>2</sup> para Apache Spark 2.0.2 y está disponible en GitHub<sup>3</sup> bajo la licencia GPL.

#### IV. MARCO EXPERIMENTAL

En esta sección primero describimos los conjuntos de datos y las medidas de rendimiento empleadas para evaluar los métodos considerados en los experimentos (Sección IV-A). Posteriormente detallamos los parámetros y la configuración del entorno utilizados para la ejecución de los algoritmos (Sección IV-B).

##### IV-A. Conjuntos de datos y medidas de rendimiento

Para llevar a cabo el estudio experimental hemos considerado 4 problemas de clasificación Big Data disponibles en los repositorios de UCI [12] y OpenML<sup>4</sup>. La Tabla I muestra la descripción de los conjuntos de datos indicando el número de instancias (#Instancias), atributos (#Atributos)

<sup>2</sup><http://www.scala-lang.org/>

<sup>3</sup><https://github.com/melkano/uniform-fuzzy-partitioning>

<sup>4</sup><https://www.openml.org/search?type=data>

reales (R)/enteros(E)/categóricos(C)/totales(T), y clases (#Clases). Los nombres de BNG Australian (BNG) y HEPMASS (HEPM) han sido abreviados. En todos los experimentos se ha empleado un esquema de validación cruzada estratificada de 5 particiones.

Tabla I: Descripción de los conjuntos de datos.

Dataset	#Instancias	#Atributos				#Clases
		R	E	C	T	
BNG	1,000,000	8	6	0	14	2
HEPM	10,500,000	28	0	0	28	2
HIGGS	11,000,000	28	0	0	28	2
SUSY	5,000,000	18	0	0	18	2

El rendimiento en clasificación se ha medido empleando la denominada matriz de confusión (Tabla II), la cual almacena el número de ejemplos clasificados correcta e incorrectamente para cada clase. De esta matriz podemos obtener las siguientes

Tabla II: Matriz de confusión para un problema binario.

	Predicción positiva	Predicción negativa
Clase positiva	Verdadero positivo (TP)	Falso Negativo (FN)
Clase negativa	Falso Positivo (FP)	Verdadero Negativo (TN)

cuatro medidas:

- Ratio de verdaderos positivos: porcentaje de ejemplos positivos clasificados correctamente.  
 $TP_{rate} = TP / (TP + FN)$ .
- Ratio de verdaderos negativos: porcentaje de ejemplos negativos clasificados correctamente.  
 $TN_{rate} = TN / (TN + FP)$ .
- Ratio de falsos positivos: porcentaje de ejemplos negativos clasificados incorrectamente.  
 $FP_{rate} = FP / (FP + TN)$ .
- Ratio de falsos negativos: porcentaje de ejemplos positivos clasificados incorrectamente.  
 $FN_{rate} = FN / (FN + TP)$ .

Basados en estas métricas, el rendimiento de clasificación de cada método se ha medido empleando el porcentaje de precisión y el Área Bajo la Curva ROC (AUC) definidas como:

$$\%Precision = (TP + TN) / (TP + FN + FP + TN) \quad (4)$$

$$AUC = (1 + TP_{rate} + FP_{rate}) / 2 \quad (5)$$

##### IV-B. Parámetros y configuración del entorno

En cuanto a los parámetros utilizados para FMDT, hemos fijado los valores sugeridos por los autores en el artículo original [9]:

- Medida para calcular la impureza de los nodos: entropía difusa
- T-norma: producto
- Máximo número de bins para los atributos numéricos: 32



- Máxima profundidad del árbol: 5
- $\gamma = 0.1\%$ ;  $\phi = 0.02 \cdot N$ ;  $\lambda = 10^{-4} \cdot N$

Todos los métodos han sido ejecutados en un cluster de 8 nodos conectados a una Red de área Local Ethernet a 1Gb/s. La mitad de estos nodos están compuestos por 2 procesadores Intel Xeon E5-2620 a 2.4 GHz (3.2 GHz con Turbo Boost) con 12 núcleos virtuales en cada uno (de los cuales 6 son físicos). Tres de los nodos restantes están equipados con 2 procesadores Intel Xeon E5-2620 a 2.1 GHz con el mismo número de núcleos que los anteriores. El último nodo es el master, compuesto por un procesador Intel Xeon E5-2609 con 4 núcleos físicos a 2.4 GHz. Todos los nodos esclavos están equipados con 32GB de RAM, mientras que el maestro trabaja con 8GB de RAM. Con respecto al almacenamiento, todos los nodos emplean discos duros con velocidades de lectura/escritura de 128 MB/s. Todo el cluster funciona sobre CentOS 6.5, Apache Hadoop 2.6.0, y Apache Spark 2.0.2.

De acuerdo con los autores de FMDT, emplear más de 24 núcleos de CPU tiene un impacto negativo en el tiempo de ejecución de este método. Por consiguiente, hemos empleado 6 *executors* con 4 núcleos cada uno para ejecutar FMDT.

## V. ESTUDIO EXPERIMENTAL

Para evaluar el rendimiento de nuestra propuesta hemos llevado a cabo un estudio empírico que cubre tres aspectos: rendimiento en la clasificación (Tabla III), complejidad del modelo (Tabla IV), y tiempo de ejecución (Tabla V). En todos los casos hemos considerado cuatro métodos: el FMDT original [9] y tres configuraciones diferentes del método propuesto que difieren en el número de conjuntos difusos ( $X$ ) utilizados para los atributos numéricos (denotado como FMDT $_X$ ). Cabe señalar que el método FMDT original se quedó sin memoria mientras procesaba HEPMASS debido al gran número de hojas que se generaron a lo largo del entrenamiento, y por tanto no se muestran resultados para este método en HEPMASS.

Las Tablas III y IV revelan que el método de particionamiento difuso propuesto (FMDT $_X$ ) es capaz de mantener el rendimiento de clasificación de FMDT con modelos notablemente más simples. Las diferentes configuraciones de nuestra aproximación rinden de forma similar en términos de precisión y AUC (excepto en HIGGS), a pesar de que hay una tendencia positiva a favor del uso de más conjuntos difusos. Sin embargo, emplear más conjuntos difusos suele causar que el algoritmo de aprendizaje genere más hojas, aumentando la complejidad del modelo. A continuación analizamos los resultados obtenidos en cada uno de los conjuntos de datos:

- BNG: nuestro método mejora la precisión y el AUC de FMDT un 6% y un 8%, respectivamente. A pesar de que los árboles construidos por FMDT $_X$  son más profundos, éstos tienen entre 8 mil y 80 mil veces menos de hojas que FMDT.
- HEPM: el FMDT original construye demasiadas hojas como para poder afrontar este problema con el cluster descrito en la Sección IV-B, quedándose sin memoria durante la ejecución. Este hecho sugiere que nuestra

aproximación es una solución candidata para evitar la explosión del número de hojas durante la inducción de los ADDs.

- HIGGS: el rendimiento de clasificación de FMDT $_5$  en este problema cae casi un 1% con respecto al resto de métodos, revelando que 5 conjuntos difusos no son suficientes para capturar la complejidad de este problema. Sin embargo, el resto de configuraciones (FMDT $_7$  y FMDT $_9$ ) son capaces de mantener el rendimiento de clasificación de FMDT con 15 mil y 50 mil hojas, respectivamente, mientras que FMDT genera 6 millones de hojas. Además, el método de particionamiento difuso original genera casi el doble de conjuntos difusos que FMDT $_7$ .
- SUSY: todas las configuraciones rinden de forma similar a FMDT en términos de capacidad de discriminación. Sin embargo, nuestro método construye árboles de 3 mil, 15 mil, y 50 mil hojas, mientras que FMDT genera 5 millones de hojas. En este caso, la diferencia en el número de conjuntos difusos empleados por cada método es aún mayor, ya que FMDT utiliza casi 23 conjuntos de datos por atributo.

Tabla III: Rendimiento de clasificación de cada método.

Dataset	%Precision			
	FMDT	FMDT $_5$	FMDT $_7$	FMDT $_9$
BNG	80.23 $\pm$ 0.05	86.79 $\pm$ 0.06	86.93 $\pm$ 0.07	86.97 $\pm$ 0.06
HEPM	-	91.13 $\pm$ 0.02	91.25 $\pm$ 0.02	91.33 $\pm$ 0.02
HIGGS	71.54 $\pm$ 0.02	70.61 $\pm$ 0.02	71.32 $\pm$ 0.03	71.69 $\pm$ 0.03
SUSY	79.29 $\pm$ 0.05	79.15 $\pm$ 0.04	79.49 $\pm$ 0.04	79.66 $\pm$ 0.04
Dataset	AUC			
	FMDT	FMDT $_5$	FMDT $_7$	FMDT $_9$
BNG	.7896 $\pm$ .0004	.8649 $\pm$ .0006	.8658 $\pm$ .0007	.8662 $\pm$ .0007
HEPM	-	.9113 $\pm$ .0002	.9125 $\pm$ .0002	.9133 $\pm$ .0002
HIGGS	.7143 $\pm$ .0001	.7033 $\pm$ .0002	.7114 $\pm$ .0003	.7155 $\pm$ .0003
SUSY	.7859 $\pm$ .0004	.7847 $\pm$ .0004	.7880 $\pm$ .0004	.7898 $\pm$ .0004

La Tabla V muestra el tiempo requerido por cada método para las tres fases: particionamiento difuso, la inducción del ADD, y el tiempo total. En general, no hay diferencias significativas entre los diferentes métodos cuando se trata de la fase de particionamiento, a pesar de que el algoritmo propuesto es un 30% más rápido que el método original en SUSY. Sin embargo, cuando se considera la inducción del ADD, la reducción en la complejidad del modelo cuando se emplea nuestro método resulta en tiempos de ejecución mucho más rápidos.

## VI. CONCLUSIONES

En este trabajo hemos presentado un nuevo método de particionamiento difuso distribuido que reduce la complejidad del modelo de los árboles de decisión difusos (ADDs) multi-*vía* en problemas de clasificación Big Data. El algoritmo

Tabla IV: Complejidad de cada modelo.

Número de hojas				
Dataset	FMDT	FMDT <sub>5</sub>	FMDT <sub>7</sub>	FMDT <sub>9</sub>
BNG	83,044	1,211	4,807	9,492
HEPM	-	2,854	13,472	43,339
HIGGS	6,414,575	3,005	15,876	53,489
SUSY	5,225,134	2,977	14,989	49,038
Profundidad media				
Dataset	FMDT	FMDT <sub>5</sub>	FMDT <sub>7</sub>	FMDT <sub>9</sub>
BNG	3.02	4.67	5.00	4.35
HEPM	-	4.52	4.03	3.93
HIGGS	3.25	5.00	5.00	4.89
SUSY	3.68	5.00	5.00	4.76
Promedio de número de conjuntos difusos				
Dataset	FMDT	FMDT <sub>5</sub>	FMDT <sub>7</sub>	FMDT <sub>9</sub>
BNG	6.04	5.00	7.00	9.00
HEPM	-	5.00	7.00	9.00
HIGGS	13.01	5.00	7.00	9.00
SUSY	22.60	5.00	7.00	9.00

Tabla V: Tiempos de ejecución(s) de cada método.

Particionamiento				
Dataset	FMDT	FMDT <sub>5</sub>	FMDT <sub>7</sub>	FMDT <sub>9</sub>
BNG	58	41	40	40
HEPM	-	295	292	294
HIGGS	252	273	274	276
SUSY	110	77	72	77
Aprendizaje				
Dataset	FMDT	FMDT <sub>5</sub>	FMDT <sub>7</sub>	FMDT <sub>9</sub>
BNG	25	23	22	24
HEPM	-	149	158	153
HIGGS	4,984	176	167	158
SUSY	1,282	76	75	77
Tiempo total				
Dataset	FMDT	FMDT <sub>5</sub>	FMDT <sub>7</sub>	FMDT <sub>9</sub>
BNG	84	65	63	65
HEPM	-	445	450	448
HIGGS	5,238	450	441	435
SUSY	1,392	154	148	155

propuesto consiste en transformar el conjunto de entrenamiento original de tal forma que todas las variables numéricas sigan una distribución uniforme estándar. Para ello se aplica la transformada integral de la probabilidad, la cual afirma que cualquier variable aleatoria continua puede ser convertida en una variable aleatoria uniforme en base a la función de distribución acumulada (FDA) original. Dado que la FDA es generalmente desconocida, proponemos aproximar esta función calculando los  $q$ -cuantiles del conjunto de entrenamiento e interpolando linealmente entre dichos cuantiles. Después de esta transformación, se crean las particiones difusas de Ruspini distribuyendo un número fijo de funciones de pertenencia

triangulares de forma uniforme a lo largo del intervalo  $[0,1]$ . Para recuperar los puntos que definen los conjuntos difusos en el espacio original se aplica la función cuantil. El método de particionamiento propuesto es capaz de ajustar tanto la posición como la forma de los conjuntos difusos a la distribución real del conjunto de entrenamiento.

Para evaluar el rendimiento de nuestra propuesta, hemos realizado un estudio empírico que se centra en el algoritmo de inducción de ADDs multi-vía propuesto por Segatori et al. para Big Data (FMDT). Para ello, hemos reemplazado el método de particionamiento difuso original por el método propuesto, sin modificar la fase de inducción del ADD. Los resultados experimentales revelan que nuestro algoritmo genera árboles significativamente más simples que son capaces de mantener el rendimiento de clasificación del método original.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Ciencia, Innovación y Universidades de España con el proyecto TIN2016-77356-P.

#### REFERENCIAS

- [1] J. R. Quinlan, *C4.5: Programs for Machine Learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1993.
- [2] M.-Y. Chen, "Predicting corporate financial distress based on integration of decision tree classification and logistic regression," *Expert Systems with Applications*, vol. 38, no. 9, pp. 11 261–11 272, 2011.
- [3] C.-C. Yang, S. Prasher, P. Enright, C. Madramootoo, M. Burgess, P. Goel, and I. Callum, "Application of decision tree technology for image classification using remote sensing data," *Agricultural Systems*, vol. 76, no. 3, pp. 1101–1117, 2003.
- [4] D. Che, Q. Liu, K. Rasheed, and X. Tao, "Decision tree and ensemble learning algorithms with their applications in bioinformatics," *Advances in Experimental Medicine and Biology*, vol. 696, pp. 191–199, 2011.
- [5] J. Sanz, D. Paternain, M. Galar, J. Fernandez, D. Reyer, and T. Belzunegui, "A New Survival Status Prediction System for Severe Trauma Patients Based on a Multiple Classifier System," *Computer Methods and Programs in Biomedicine*, vol. 142, no. C, pp. 1–8, 2017.
- [6] L. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338 – 353, 1965.
- [7] C. Janikow, "Fuzzy decision trees: Issues and methods," *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 28, no. 1, pp. 1–14, 1998.
- [8] J. Sanz, H. Bustince, A. Fernández, and F. Herrera, "IIVFDT: Ignorance functions based interval-valued fuzzy decision tree with genetic tuning," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 20, no. SUPPL. 2, pp. 1–30, 2012.
- [9] A. Segatori, F. Marcelloni, and W. Pedrycz, "On Distributed Fuzzy Decision Trees for Big Data," *IEEE Transactions on Fuzzy Systems*, vol. 26, no. 1, pp. 174–192, 2018.
- [10] J. E. Angus, "The Probability Integral Transform and Related Results," *SIAM Review*, vol. 36, no. 4, pp. 652–654, 1994.
- [11] E. H. Ruspini, "A new approach to clustering," *Information and Control*, vol. 15, no. 1, pp. 22–32, 1969.
- [12] D. Dheeru and E. Karra Taniskidou, "UCI machine learning repository," 2017. [Online]. Available: <http://archive.ics.uci.edu/ml>
- [13] H. Ishibuchi, T. Nakashima, and M. Nii, *Classification and Modeling with Linguistic Information Granules: Advanced Approaches to Linguistic Data Mining (Advanced Information Processing)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2004.
- [14] M. Zeinalkhani and M. Eftekhari, "Fuzzy partitioning of continuous attributes through discretization methods to construct fuzzy decision tree classifiers," *Information Sciences*, vol. 278, pp. 715–735, 2014.
- [15] N. U. Nair, P. G. Sankaran, and N. Balakrishnan, *Quantile-Based Reliability Analysis*. New York, NY: Springer New York, 2013, ch. Quantile Functions, pp. 1–28.



# EDGAR-MR: un algoritmo evolutivo distribuido escalable para la obtención de reglas de clasificación

Miguel Ángel Rodríguez

Departamento de Tecnologías de la Información  
Universidad de Huelva  
Huelva, España

Antonio Peregrín

Centro de Estudios Avanzados en Física,  
Matemáticas y Computación  
Universidad de Huelva  
Huelva, España

**Resumen.** El modelo evolutivo para la obtención de reglas de clasificación, EDGAR, cuenta entre sus especificidades con diferentes estrategias para resolver el problema del aprendizaje distribuido de reglas cuando el conjunto de entrenamiento está dividido en diferentes subconjuntos. Sin embargo, el modelo encuentra limitaciones prácticas a su escalabilidad con un número creciente de particiones de datos. Las actuales tecnologías derivadas de los principios de MapReduce en cambio, pueden ayudar a resolver dicha limitación facilitando una implementación más escalable del modelo evolutivo distribuido EDGAR, manteniendo aspectos de su esencia. Es este trabajo se desarrolla una primera aproximación práctica a dicho modelo.

**Palabras clave:** Big Data, Algoritmos Genéticos Distribuidos, EDGAR, MapReduce, Clasificación, Programación Distribuida.

## I. INTRODUCCION

Actualmente, enormes cantidades de datos son recogidas y almacenadas en bases de datos. El fin último de la Minería de Datos es obtener información de interés en forma de modelos precisos y entendibles de estas bases de datos. Dentro de esta disciplina, los sistemas de clasificación basados en reglas son un instrumento tradicional de gran utilidad. La extracción de reglas de un conjunto de datos depende en gran medida de la topología de los datos y del volumen de éstos. Adicionalmente, a medida que el volumen de datos crece, su manejo es más complejo, el tiempo necesario para su tratamiento se incrementa de manera exponencial, y además crece la dificultad de aprendizaje del algoritmo.

Los algoritmos evolutivos han demostrado una gran capacidad como recurso para extraer conocimiento, siendo robustos al ruido y a otras características inherentes a los datos; sin embargo, suele ser difícil escalar un algoritmo evolutivo eficientemente, debido al cálculo reiterativo de la bondad de los individuos que implica la evaluación de un conjunto de reglas sobre el conjunto de datos.

En este sentido, el algoritmo evolutivo distribuido para obtener reglas de clasificación, EDGAR [1], propone un sistema de distribución de poblaciones y repartición de datos que permite escalar en varias magnitudes el número de instancias que es capaz de manejar eficientemente un algoritmo evolutivo de sus características. No sólo eso, EDGAR también emplea otras estrategias dirigidas al manejo de conjuntos de datos con clases no balanceadas sin preprocesamiento específico. Sin embargo,

existen límites inherentes a la arquitectura que utiliza, los cuales se pueden confirmar en la práctica.

En los últimos años, la aparición del paradigma *MapReduce* [2] y el sistema de almacenamiento HDFS [3], ha impulsado relevantes mejoras en la escalabilidad. No obstante, no todos los algoritmos son directamente aptos para implementarse directamente de forma equivalente, y por tanto, en tales casos es necesario establecer estrategias que conserven la calidad de los resultados y mantengan el tiempo de ejecución a niveles competitivos en relación a otras alternativas distribuidas.

Este trabajo propone un algoritmo evolutivo escalable para la obtención de reglas de clasificación basado en los principios de EDGAR, implementado sobre el paradigma *MapReduce*, y realiza una experimentación preliminar para comprobar la validez los conceptos propuestos.

La organización de este trabajo es la siguiente: en la primera Sección se introduce el esquema general del algoritmo evolutivo EDGAR. La Sección 2.1 se dedica a exponer las alternativas de implementación del modelo distribuido sobre *MapReduce*. La Sección 3 se centra específicamente en la adaptación de las estrategias para conjuntos de datos no balanceados. Finalmente, la Sección 4 analiza los resultados de precisión, calidad y escalabilidad sobre una experimentación preliminar con conjuntos de datos de diversas características.

## II. ANTECEDENTES

En esta Sección se repasan, para el aprendizaje de clasificadores, en primer lugar, las principales referencias en el área de los algoritmos genéticos distribuidos, y en segundo lugar, las propuestas que emplean *MapReduce*.

### A. Modelos evolutivos distribuidos para el aprendizaje de clasificadores

Una de las primeras referencias reseñables en este ámbito es REGAL [4]. Éste propone una división de datos en nodos que contienen algoritmos genéticos (AGs) para el aprendizaje de reglas. Posteriormente refina dichas reglas asignando cada una de ellas y sus datos asociados a diferentes nodos. REGAL-TC [5] es una propuesta que mejora la precisión de REGAL a través de un ponderado de contra-ejemplos y otras estrategias. NowGNet [6] por su parte, propone una mejora sobre el mismo esquema utilizando un buffer de reglas a evaluar que separa las

funciones de evaluación del individuo y del AG, lo cual permite un mayor grado de paralelización. Estos tres algoritmos tienen en común la presencia de un proceso supervisor síncrono que en base a los resultados parciales de los nodos redistribuye datos y reglas a los nodos subordinados.

EDGAR utiliza un modelo mixto de nodos *aprendedores* independientes, que emplean un AG local (AGL), con un subconjunto de los datos y supervisor central. El sistema es asíncrono, utilizando una copia del conjunto global de datos para evaluar las reglas generadas por los AGLs y generar un clasificador final basado en la cobertura y calidad de ellas sobre el conjunto de datos de entrenamiento (Figura 1). El AGL utiliza una codificación de tipo *un individuo = una regla*, dentro del paradigma GCCL; la población representa un conjunto redundante de reglas y la solución del mismo es un clasificador compuesto por un subconjunto de las mismas que clasifica al conjunto de los datos asignados.

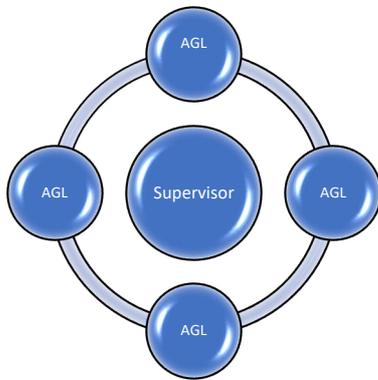


Fig. 1. Modelo distribuido de EDGAR: poblaciones de algoritmos genéticos y datos con particiones en nodos y nodo central con conjunto completo

La regla se representa como una cadena binaria donde cada posible valor de un atributo está asociado a un bit. Esta representación puede tener varios valores activos en cada atributo, consiguiendo un lenguaje de descripción de conceptos compacto, pero por otra parte requiere que los conjuntos de datos continuos sean discretizados previamente. La clase también está representada en el cromosoma con un único valor a la vez (Figura 2).

$c_1$			$c_2$			$c_3$			$Clase$
$v_1$	$v_2$	$v_3$	$v_4$	$v_5$	$v_6$	$v_7$	$v_8$	$v_9$	$v_{10}$
1	0	1	0	0	1	0	0	0	1

*si  $c_1$  en  $(v_1, v_3)$  y  $c_3$  en  $(v_1)$  entonces clase es  $v_2$*

Fig. 2. Ejemplo de representación de regla en EDGAR a formato binario

Las mejores reglas, por calidad y cobertura, se intercambian periódicamente entre nodos para favorecer la cooperación entre los AGLs de modo similar al modelo de AGs distribuidos

basado en Islas [9] y se envían a un nodo central que hace las veces de supervisor. Este nodo dispone de una copia del conjunto global de datos que utiliza para reevaluar las reglas recibidas y generar un clasificador final basado en la cobertura y calidad de ellas sobre el conjunto completo de datos de entrenamiento. El supervisor manda una señal de terminación a los nodos AGL cuando el clasificador generado no mejora durante un periodo de tiempo y genera el clasificador como una lista ordenada en base al valor de las reglas sobre el conjunto completo de datos.

### B. MapReduce en el ámbito del aprendizaje de clasificadores

MapReduce [1] permite un modelo de diseño paralelo basado en la división de datos. Este modelo se basa en la existencia de un conjunto de datos distribuidos que permiten una alta escalabilidad de datos y la codificación de tareas sobre estos basados fundamentalmente en dos operaciones *Map* y *Reduce*.

Centrándonos en el aprendizaje de modelos de clasificación, hay técnicas que se prestan mejor que otras para este paradigma porque no necesitan de un acceso repetido a los datos. En este sentido, la generación de clasificadores con *Random Forest* [7] implementado bajo *MapReduce* realiza la evaluación de múltiples árboles de decisión eficientemente. Un ejemplo reciente de este uso puede verse en [8].

Otro algoritmo directamente compatible con esta arquitectura es el de generación de reglas basadas en ejemplos como semillas que posteriormente formarán el clasificador. En [10] se generan reglas en la fase *Map* en base a un conjunto de etiquetas lingüísticas que son evaluadas en la fase de construcción y posteriormente seleccionadas en la fase *Reduce* para generar el conjunto de reglas final teniendo en cuenta el coste de la clasificación en caso de existir clases no balanceadas.

### III. EL MODELO EDGAR-MR

En este apartado proponemos una versión del modelo EDGAR sobre el paradigma *MapReduce*. Esta versión, a la que denominamos EDGAR-MR, aprovecha las mejoras en eficiencia, robustez y facilidad de ejecución con conjuntos de datos de alta cardinalidad que proporciona *MapReduce* manteniendo un modelo de calidad y precisión en conjuntos de datos complejos.

Como se ha indicado anteriormente, EDGAR lleva a cabo el aprendizaje de reglas empleando un conjunto de AGLs, en lo que cada uno de ellos trabaja sobre una fracción del conjunto completo de datos. Este modelo de datos distribuido es parcialmente compatible con el paradigma *MapReduce*, ya que el aprendizaje de reglas está asociado a las particiones de datos, y la ulterior extracción del clasificador final es una tarea independiente. Sin embargo, EDGAR emplea mecanismos cuya adaptación al modelo *MapReduce*, por los principios de éste, no pueden llevarse a cabo, como son por ejemplo aquellos relacionados con la cooperación entre AGLs basado en el intercambio de reglas.

En el resto de esta Sección pues, se va a describir el diseño concreto empleado para el modelo EDGAR-MR.

Las fases principales de EDGAR-MR (fig. 3) son:



- Inicial, carga de datos: Preparación de conjuntos de datos para iniciar el proceso distribuido.
- Fase de aprendizaje de reglas: Es llevada a cabo por los AGLs implementados en los *Map*, y en ella, cada uno aprende un clasificador local basado en su partición de datos.
- Fase de agregación de reglas: Las reglas provenientes de los *Map* son procesadas en nodos *Reduce* para generar una única regla que agrega los casos positivos y negativos encontrados en los *Map*.
- Fase de generación del clasificador: el clasificador se genera como una lista ordenada de reglas por mayor cobertura y calidad.
- Fase de *test*: se clasifican los conjuntos de *test* con el clasificador generado para tener una medida de precisión del mismo.

antecedentes. La función hash codifica en un número en base 10 la codificación binaria de la clase. Por ejemplo, en un conjunto de datos con 3 atributos de tres valores cada uno y dos clases, EDGAR usa 11 bits para su codificación; por tanto el rango de la clave se encuentra entre 20 y 211. Si se implementa con 2 nodos *Reduce*. Las reglas con clave entre 0 y 210 serán asignados al primero y las claves entre 210 y 211 se asignan al segundo. El pseudocódigo 1 muestra el detalle de este *Map*.

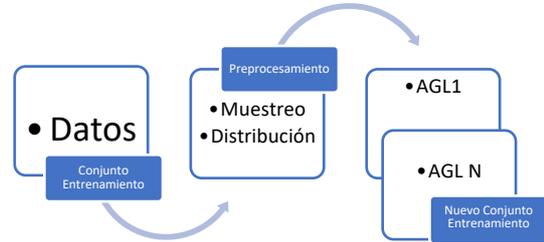


Fig. 4. Esquema de rebalanceo inicial de clases en fase de carga inicial

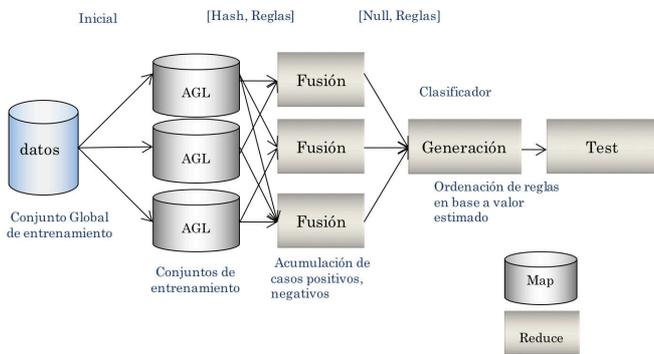


Fig. 3. Esquema *MapReduce* de las fases de aprendizaje, agregación, generación de clasificador y *test*

A continuación se describe en detalle en cada una de las fases :

### A. Inicial, carga de datos

El proceso de aprendizaje requiere una partición de los datos en los nodos *Map* en bloques HDFS independientes que son replicados y transferidos a otras máquinas para ser procesados por cada tarea *Map* independiente. Esta partición es realizada mediante un muestreo aleatorio de cada clase teniendo en cuenta equilibrar las clases en los AGL en caso de existir desbalanceo (figura 2). Otro paso de esta preparación inicial consiste en la recodificación en el formato de cromosoma binario que será utilizado por los AGL en los *Map*.

### B. Fase de aprendizaje de reglas (*Map*)

Cada AGL genera un conjunto de de reglas que cubre completamente el conjunto de los datos en el nodo. La salida del *Map* son conjuntos (*Key*, *Value*), donde *Value* corresponde a la regla concatenada con el número de casos positivos y negativos que cubre y *Key* contiene un valor generado mediante una función hash para repartir la carga sobre los nodos *Reduce*. Esta función utiliza una codificación sobre los antecedentes de la regla para reunir en el mismo *Reduce* las reglas con los mismos

```

Input (Key, Value)
Key, Valor no utilizados, Map inicial.
AGL.generarClasificador(ConjuntoDatosLocal)
Para cada Regla en el clasificador
    Key' : Valor decimal (Regla)
    Valor: (Regla, casos positivos, casos negativos)
    Emit (Key', Valor)
Fin Para
    
```

Pseudocódigo 1. Fase de aprendizaje de reglas (*Map*)

### C. Fase de agregación de reglas (*Reduce*)

Este proceso combina los conjuntos de reglas recibidos de cada *Map*, fusionando las reglas con los mismos antecedentes. El proceso de fusión es como sigue: acumula los casos positivos y negativos de las reglas con los mismos antecedentes para cada clase y crea una nueva regla fusionada. La nueva regla tendrá la clase de la regla con mayor valor ponderado de cobertura y calidad, denominado  $\Pi$  (1). Éste criterio minimiza la longitud de la regla y cobertura de casos negativos y maximiza la cobertura de casos positivos.

$$\Pi = (1 + longitud^{-1})^{-CasosNeg} * CasosPos \quad (1)$$

```

Input (Key, Values)
Key es una clave hash calculada en base a la regla
Values: las reglas generadas por los AGLs en los Map
ArrayList auxReglas= new ArrayList();
Para cada Regla en values
    Si (Regla not in auxReglas) auxReglas.add(Regla)
    Sino
        AuxReglas.get(Regla).AcumulaCasos(Regla)
    Fin Si
Fin Para
Para cada Regla en auxReglas
    Emit (null, auxReglas)
Fin Para
    
```

Pseudocódigo 2. *Reduce*, aprendizaje. Fusión de reglas

La salida del proceso *Reduce* es un conjunto de reglas con información necesaria para el proceso de generación del clasificador: casos positivos, casos negativos (pseudocódigo 2).

**D. Fase de generación del clasificador:**

El clasificador producido EDGAR originalmente, es generado mediante la evaluación de las reglas sobre el conjunto completo de datos de entrenamiento y la posterior ordenación en una lista ordenada donde cada regla elimina las instancias cubiertas por las predecesoras.

Sin embargo, en la propuesta de este trabajo, la agregación de reglas aprendidas sobre modelos locales puede no tener la misma validez sobre el conjunto completo de datos, por ello se han implementado dos variantes dependiendo del método de cálculo del valor de la regla:

- Estimado: toma como valor de ordenación para la generación del clasificador los casos positivos y negativos calculados por la fase de agregación de reglas.
- Evaluación global: efectúa una re-evaluación de las reglas generadas en la fase de agregación de reglas mediante otro ciclo *MapReduce* con el conjunto de datos preexistente en cada *Map* (pseudocódigo 3). La salida de los *Map* será acumulada en un *Reduce* que tendrá como resultado una lista de reglas con valores positivos y negativos relativos al conjunto completo de datos (fig. 5).

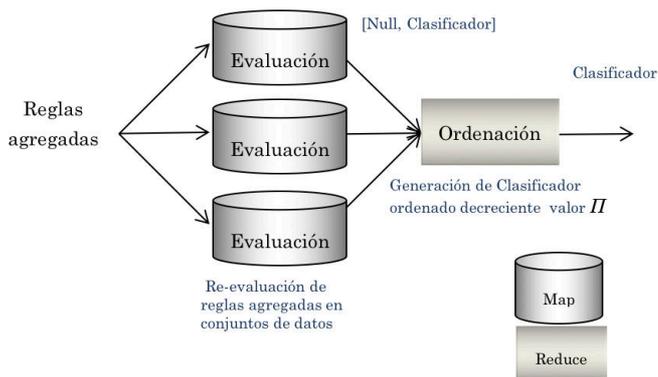


Fig. 5. Esquema *MapReduce* de la re-evaluación de reglas en variante de evaluación global en la fase de generación del clasificador

Finalmente se genera un clasificador como una lista ordenada de reglas en base al valor decreciente de  $\Pi$  (1).

```

Input (Key, Value)
Value es conjunto de reglas generado por el Reduce de agregación de reglas
ArrayList auxReglas = new ArrayList()
auxReglas, auxpi = GenerarClasificadorGredy(Values, Datos de test Local)
posición=0;
Para cada Regla en auxReglas
    posición ++
    Valor = Regla + Auxpi + casos positivos y negativos + posición
Fin Para
    
```

Pseudocódigo 3. Map de fase de evaluación global

**E. Fase de test**

Habitualmente se siguen esquemas de aprendizaje que reservan un 10% o un 20% del tamaño del conjunto de datos para *test*, en alguna de las configuraciones propuestas para minimizar la fractura de datos en el proceso de aprendizaje. En conjuntos de datos grandes, la medida de la precisión del clasificador generado implica en si misma la asignación de grupos de datos siguiendo un esquema de distribuido de datos y por tanto la ejecución de un nuevo ciclo *MapReduce*.

Inicialmente se carga en los nodos el conjunto de *test*. El *Map* se encarga de aplicar el clasificador generado sobre cada ejemplo generando como salida una línea para cada instancia con el valor real y el predicho (Fig. 6). El proceso *Reduce* acumula los aciertos y fallos en cada ejemplo respecto de la clase predicha generando un informe que puede ser utilizado para realizar distintas variantes de cálculo de la precisión sobre clasificadores.

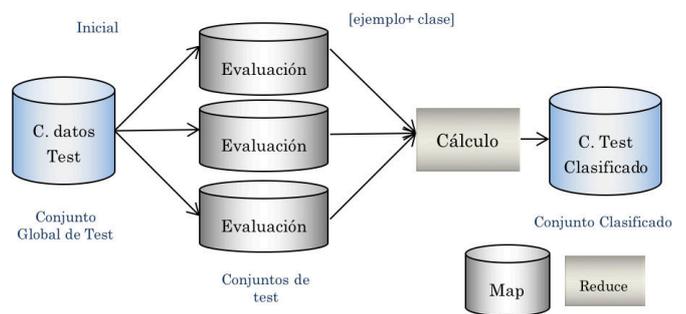


Fig. 6. Cálculo de la precisión en fase *test*

**IV. ESTUDIO EXPERIMENTAL**

Esta sección muestra una experimentación tentativa sobre un conjunto de *datasets* representativos para valorar la validez de la propuesta y un algoritmo de referencia no distribuido. Se estimará la calidad del clasificador generado en base al la interpretabilidad del mismo (número de reglas) y precisión (media geométrica). Asimismo se mostrará la escalabilidad del mismo según el rendimiento alcanzado respecto del número de *Maps*.

**A. Entorno de Experimentación**

El entorno de experimentación se basa en un cluster Hadoop compuesto por 13 nodos. Cada nodo es una máquina virtual sobre un servidor basado en memoria común y multiprocesador: 192GB de memoria RAM, 40 núcleos con *hyperthreading* y sistema operativo CentOS 7 de 64 bits. Todo el desarrollo se ha realizado en Java. Las características de las máquinas virtuales son:

Nodo maestro:

- Sistema operativo CentOS 7 64 bits, y 8 núcleos.
- 16 GB de memoria RAM.
- 20 GB de almacenamiento en disco configurado en modo dinámico.



Nodos esclavos:

- Sistema operativo CentOS 7 64 bits, y 4 núcleos.
- 12 GB de memoria RAM.
- 20 GB de almacenamiento en disco configurado en modo dinámico.

Respecto de los conjuntos de prueba se han seleccionado *datasets* balanceados y no balanceados con distintas cardinalidades y dimensionalidades. Éstos se encuentran disponibles en los repositorios UCI [12] y KEEL [13]. Los conjuntos de datos con atributos continuos han sido discretizados para EDGAR-MR usando Chi2-Merge [14]. Las tablas muestran valores medios de ejecuciones con 10 semillas y 5x2 particiones de datos.

TABLA I. CARACTERÍSTICAS DE LOS CONJUNTO DE DATOS

Nombre	Instancias	Atributos	IR
Mushroom	8124	23	0.93
Page-blocks0	5472	10	8.77
Segment0	2308	19	6.01
Yeast3	1484	8	8.11

Los algoritmos genéticos utilizados como aprendedores en los *Map* (AGLs) siguen la estructura de operadores de EDGAR con la siguiente configuración:

- Probabilidad de Mutación = 0.01
- Tamaño de población = 40
- Número de iteraciones de parada = 500

### B. Análisis

En la tabla II se observa que la precisión en *test* con media geométrica de las dos modalidades de aprendizaje, con la opción de balanceo de clases a los nodos mediante redistribución aleatoria de las instancias, sin balanceo y con aplicación del método de balanceo SMOTE [11] respecto del algoritmo de referencia C4.5 para una distribución de 12 nodos. El acrónimo NA (*No Aplica*) en la columna del conjunto de datos Mushroom refleja el hecho de que no se aplica el método de rebalanceo por tratarse de un dataset balanceado en origen. Para facilitar la visualización de los datos se ha sombreado levemente la fila correspondiente a la variante EDGAR-MR Global en las tablas II a IV.

En relación de la comparación entre las dos variantes, EDGAR-MR Estimado y Edgar-MR Global, se aprecia que la precisión de la variante con evaluación global alcanza en general las mismas cotas de precisión que el estimado. Acerca de la eficacia del método de rebalanceo, se observa que si bien la aplicación previa de balanceado con SMOTE, permite que EDGAR-MR alcance mejores niveles de precisión (muy apreciable en la precisión alcanzada sobre *Yeast3* para la variante global), el método de redistribución puede ser una alternativa válida, que para algunos conjunto de datos, puede llegar a superar al estándar de facto en el preprocesamiento para

desbalanceadas, SMOTE. Se puede observar este caso en las precisiones alcanzadas sobre *Page-blocks0*, que son superadas por la variante de rebalanceo mediante la distribución balanceada de clases a los nodos (redistribución).

*Mushroom* es típicamente un conjunto de datos robusto frente al particionamiento de datos para su aprendizaje, o dicho de otra forma no tiene un gran riesgo de fractura de datos por la división de los mismos previa al proceso de aprendizaje. Sin embargo, se observa una diferencia apreciable entre las variantes estimada y global en el número de reglas sobre este conjunto de datos, aunque la precisión sea similar en ambos. Esto puede ser debido a la representación del mismo concepto en diferentes *Maps* por reglas equivalentes, que en la variante global elimina, eligiendo sólo la mejor representante del concepto y eliminando las reglas parcial o totalmente redundantes.

TABLA II. PRECISIÓN COMPARADA EN MEDIA GEOMÉTRICA

Algoritmo	Balanceo	Mushroom	Page-blocks0	Segment	Yeast3
EDGAR-MR Estimado	Sin Banlaceo	99,8	80.84	96.55	88.97
	SMOTE	NA	83.96	97.85	88.00
	Redistribución	NA	86.39	97.02	91.01
EDGAR-MR Global	Sin Balanceo	99,9	76.08	97.23	52.07
	SMOTE	NA	81.62	98.59	87.15
	Redistribución	NA	84.96	97.14	91.30
C4.5	Sin	100	97.33	99.18	94.14
	SMOTE	NA	94.33	99.22	93.53

Relativo a la comparación con otros algoritmos de clasificación, se comprueba que el algoritmo alcanza niveles próximos a al algoritmo de referencia C4.5, sin llegar a superarlo. Probablemente el uso de conjunto de datos continuos no sea el más apropiado para un algoritmo de representación discreta y la discretización pueda afectar a la calidad del mismo.

En cuanto al número de reglas se puede observar en la tabla III, que el número de reglas generada por la variante global es claramente inferior al de la variante estimada, resultando en un clasificador más compacto. El número de reglas no se ve afectado de manera general por el método de desbalanceo, aunque se aprecia una ligera mejora del numero de reglas en el balanceo por redistribución frente a los otros.

TABLA III. NÚMERO DE REGLAS DEL CLASIFICADOR

Algoritmo	Balanceo	Mushroom	Page-blocks0	Segment	Yeast3
EDGAR-MR Estimado	Sin Balanceo	20	530	316	240
	SMOTE	NA	559	320	220
	Replica	NA	510	285	230
EDGAR-MR Global	Sin Balanceo	15	142	46	52
	SMOTE	NA	150	43	56
	Réplica	NA	144	45	49

Finalmente, en cuanto a la escalabilidad, se puede observar en la tabla IV, que existe una mejora o *speed-up* (ratio tiempo proceso original-paralelo) que dista mucho del ideal, 1/#nodos. Los tiempos indican minutos por cada configuración de nodos.

En el detalle de las ejecuciones observamos que la mayor parte del tiempo de proceso (en torno a un 70%) se consume en las tareas propias de preparación de datos, codificación en el formato de instancias y aquellos procesos en los reduce, y que en esta experimentación es un proceso único: agregación y fusión de reglas, generación de clasificador global y generación de los valores de *test* con el clasificador, siendo este tiempo similar en todas las configuraciones.

TABLA IV. TIEMPOS MEDIOS POR EJECUCIÓN

Algoritmo	#Nodos	Mushroom	Page-blocks0	Segment	Yeast3
EDGAR-MR Estimado	4	5,30	7,34	5,30	4,23
	8	4,45	6,68	4,45	3,81
	12	3,87	6,23	3,87	3,24
EDGAR-MR Global	4	5,81	7,71	5,81	4,65
	8	5,03	6,75	5,03	4,28
	12	4,34	6,34	4,34	4,02

V. CONCLUSIONES

EDGAR propuso un método eficiente para trabajar sobre conjuntos de datos particionados mediante la colaboración de algoritmos genéticos y un clasificador compacto basado en una lista ordenada validada sobre un conjunto de datos global. Sin embargo, con un número de particiones elevado disminuye la influencia de la comunicación en tiempo de aprendizaje. Asimismo la validación central, aunque de menor entidad algorítmica, supone un cuello de botella directamente ligado a la capacidad de la memoria del nodo central para albergar el conjunto completo de datos. Esta propuesta mejora la escalabilidad del modelo mediante un proceso de evaluación escalable mientras conserva el algoritmo genético de aprendizaje del original. Por otro lado no implementa la comunicación entre nodos incoherente con la implementación *MapReduce* seguida e ineficiente con un numero creciente de particiones.

Este trabajo presenta una arquitectura novedosa para la implementación de algoritmos evolutivos de clasificación basados en reglas, en el que el antecedente de la regla aprendida en distintas particiones forma una clave que permitirá su posterior fusión. Se propone asimismo un proceso de

reevaluación que aprovecha los datos ya particionados para mejorar la calidad del clasificador.

Los resultados muestran una escalabilidad creciente, aunque mejorable, con el uso de un mayor numero de fases *Reduce* en las etapas de agregación. La comparación con un algoritmo de referencia parecen mostrar que la discretización afecta a la precisión del clasificador, siendo más adecuado para conjunto de datos nominales, por lo que en futuros trabajos se planteará la posibilidad de trabajar con datos continuos en los nodos para mejorar su precisión.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Educación y Ciencia dentro del Proyecto TIN2017-89517-P.

REFERENCIAS

- [1] Rodríguez M., Escalante D. M., Peregrín A. (2011). Efficient distributed genetic algorithm for rule extraction. *Applied soft computing*, 11(1), 733-743.
- [2] Dean J., Ghemawat S. (2008): MapReduce: Simplified Data Processing on Large Clusters. *Commun ACM* 51, 107-113.
- [3] White T.(2009): Hadoop: The Definitive Guide. 1st ed.Sebastopol, CA: O'Reilly .
- [4] Giordana A., Saitta L. (1994). Learning disjunctive concepts by means of genetic algorithms. *Proceedings of the International Conference on Machine Learning*, 96-104.
- [5] Lopez L. I., Bardallo J. M., De Vega M. A., Peregrin A. (2011). REGAL-TC: a distributed genetic algorithm for concept learning based on REGAL and the treatment of counterexamples. *Soft Computing*, 15(7), 1389-1403.
- [6] Anglano C., Botta M. (2002). NOW G-Net: learning classification programs on networks of workstations. *IEEE Transactions on Evolutionary Computation*, 6(5), 463-480.
- [7] Svetnik V., Liaw A., Tong C., Culberson J. C., Sheridan, R. P., Feuston, B. P. (2003). Random forest: a classification and regression tool for compound classification and QSAR modeling. *Journal of chemical information and computer sciences*, 43(6), 1947-1958.
- [8] Río S., López S., Benítez J.M., Herrera F. (2014): On The Use of MapReduce for Imbalanced Big Data using Random Forest. *Information Sciences* 285 112-137.
- [9] Cantú-Paz E. (1998). A survey of parallel genetic algorithms. *Calculateurs paralleles, reseaux et systems repartis*, 10(2), 141-171.
- [10] Peralta D., del Río S., Ramírez-Gallego S., Triguero I., Benitez J. M., Herrera F. (2015). Evolutionary feature selection for big data classification: A MapReduce approach. *Mathematical Problems in Engineering*.
- [11] Chawla N. V., Bowyer K. W., Hall L. O., Kegelmeyer W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
- [12] Asuncion A., Newman D. (2007). UCI machine learning repository.
- [13] Alcalá-Fdez J., Fernández A., Luengo J., Derrac J., García S., Sánchez L., Herrera F. (2011). Keel data-mining software tool: data set repository, integration of algorithms and experimental analysis framework. *Journal of Multiple-Valued Logic & Soft Computing*, 17.
- [14] Liu H., Setiono R. (1995). Chi2: Feature selection and discretization of numeric attributes. In *Tools with artificial intelligence*, 1995. proceedings., seventh international conference on IEEE, 388-391.

---

# I Workshop en Deep Learning (DeepL)

SIHAM TABIK  
JUAN MANUEL GÓRRIZ  
ANTONIO BAHAMONDE





---

# I Workshop en Deep Learning (DeepL)

SESIÓN 1







# Optimización de las técnicas de Transfer Learning para la clasificación de la calidad estética en fotografía

Fernando Rubio

SIMD Lab, I3A

UCLM

Albacete, España

Email: fernando.rubio@uclm.es

M. Julia Flores

Departamento de Sistemas Informáticos

UCLM

España

Email: julia.flores@uclm.es

Jose M. Puerta

Departamento de Sistemas Informáticos

UCLM

España

Email: jose.puerta@uclm.es

**Abstract**—La evaluación automática de la calidad estética es un problema de visión por ordenador que consiste en cuantificar el atractivo de una fotografía. Esto es especialmente útil en las redes sociales, donde la cantidad de imágenes que se generan cada día requieren de la automatización para su procesamiento.

Aunque ha habido progresos notables en la investigación de este campo, aún es difícil encontrar soluciones aplicables. Con este trabajo buscamos la optimización de las soluciones más prometedoras basadas en Transfer Learning. Para ello, hemos reducido la complejidad de las redes neuronales propuestas manteniendo los resultados obtenidos, mediante técnicas de “finetuning” sobre redes pre-entrenadas.

**Index Terms**—Deep Learning, Transfer Learning, Finetuning, Classification, Computer Vision

## I. INTRODUCCIÓN

El campo de visión por ordenador es uno de los más activos en la comunidad científica debido a la gran cantidad de aplicaciones que tiene como la robótica y la seguridad. En los últimos años, las redes neuronales profundas han permitido resolver problemas, que hasta hace poco parecían inabordable. Esto ocurre también con el problema de la calidad estética.

El concepto de calidad estética en la fotografía hace referencia a las propiedades de las imágenes que las hacen atractivas o “bonitas” para la mayoría de la gente, como pueden ser los filtros aplicados, armonía de los colores, etc. No hay que confundir con la calidad de una imagen en términos de resolución. Se trata de uno de los problemas más complejos dentro del campo de visión debido a la subjetividad de la tarea, ya que la opinión de diferentes personas sobre la calidad de una única imagen puede ser muy distinta. Incluso entre expertos de fotografía puede haber opiniones diferentes.

A pesar de su dificultad, se trata de un problema que ha visto incrementado su interés enormemente debido a la gran cantidad de imágenes que se generan continuamente con las redes sociales. La automatización de esta tarea tiene aplicaciones muy interesantes como la ordenación de álbumes de imágenes en base a su calidad, especialmente útil para sitios como Flickr o Instagram. Pero también se puede utilizar para recomendaciones de filtros o incluso para evaluaciones online

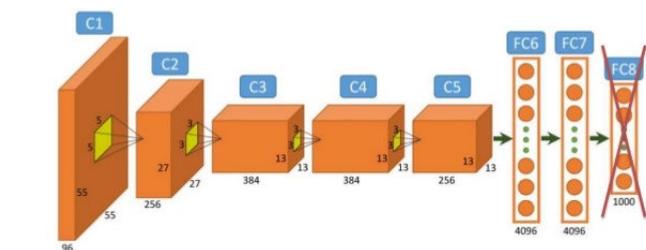


Fig. 1. Extracción de características de una red neuronal.

en una cámara, para mejorar la calidad de las fotografías que tomamos. Otro de los campos de aplicación es la publicidad, con la creación de imágenes más atractivas.

Tradicionalmente, la automatización de la evaluación de la calidad estética se centra en resolver un problema de clasificación binaria, donde las imágenes son clasificadas como “snapshots” (mala calidad) o “professional shots” (buena calidad). El uso del Deep Learning mediante las redes convolucionales ha mejorado los resultados en los últimos años e incluso ha permitido utilizar las probabilidades generadas en la última capa como indicadores más precisos de la calidad de la imagen.

En este artículo nos centramos en una de las estrategias más utilizadas recientemente en Deep Learning, Transfer Learning. Este concepto se basa en utilizar redes neuronales pre-entrenadas con otros datasets y aplicar dicho conocimiento a nuestro problema.

Actualmente, dos son las técnicas principales de Transfer Learning. La primera de ellas, puede verse en la Fig. 1 y que consiste en la extracción de características de una red neuronal, lo que se conoce como **ConvNet features** o **DeCaf** [1]. En este caso, obviamos la salida de la red y obtenemos las activaciones que se producen en las capas anteriores, para utilizarlas como *inputs* en otros modelos.

La segunda es el concepto de **finetuning**, que puede verse en la Fig. 2. Esta técnica de Transfer Learning consiste en la modificación de la (o las) última(s) capa(s) para ajustar

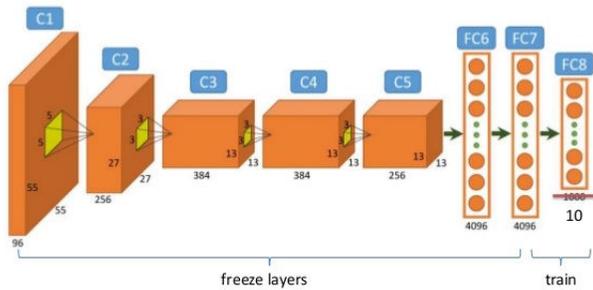


Fig. 2. Proceso de *finetuning*, donde se ha modificado la última capa de una red pre-entrenada, cuyos pesos van a ser aprendidos. El resto de capas no sufre modificaciones.

la salida de una red a nuestro problema. El siguiente paso consiste en el entrenamiento de los pesos sólo de las capas que han sido modificadas. Esto reduce el tiempo y la cantidad de datos necesarios para entrenar la red.

Cuando hablamos de Transfer Learning en imágenes, existen diferentes modelos pre-entrenados que podemos utilizar como son AlexNet [2], VGG [3], Inception [4], ResNet [5] o MobileNet [6]. Todos estos comparten una serie de propiedades y la base de datos con la que fueron entrenadas, ImageNet [7]. Este dataset consiste en un conjunto de más de 2 millones de imágenes de objetos (valla, barco, avión), animales (perro, gato, tortuga) o conceptos (atardecer, paisaje) que han sido etiquetadas con 1 de 1000 posibles “tags”. Por lo tanto, ImageNet es un problema de clasificación donde la clase puede tomar 1000 posibles valores. El objetivo de utilizar Transfer Learning sobre las redes aprendidas para este problema, es aprovechar todo el conocimiento generado por una red capaz de identificar 1000 conceptos diferentes en imágenes.

Los mejores resultados obtenidos para la clasificación de la calidad estética vienen de propuestas de Transfer Learning sobre dichos modelos, especialmente con *finetuning* [8]. Sin embargo, en el estudio de estas soluciones, por lo general, sólo la última capa es modificada para el reentrenamiento. En este trabajo proponemos realizar un proceso de *finetuning* de más capas, con el objetivo de reducir el tamaño de la red, pero sin afectar a los resultados obtenidos. Esto permitirá que las redes neuronales puedan utilizarse en dispositivos más limitados en recursos computacionales como son los dispositivos móviles o las cámaras fotográficas, permitiendo la creación de aplicaciones reales.

## II. ESTADO DEL ARTE

Las primeras aproximaciones para la evaluación de la calidad estética consisten en una clasificación binaria de las imágenes en “snapshots” o “professional shots”. Sin embargo, al tratarse de un problema con tanta incertidumbre y donde la clase no está bien definida, las principales bases de datos están compuestas por imágenes donde un grupo de individuos han asignado unos ratings o votos [9]. En la Fig. 3, podemos observar dos imágenes con su distribución de votos.

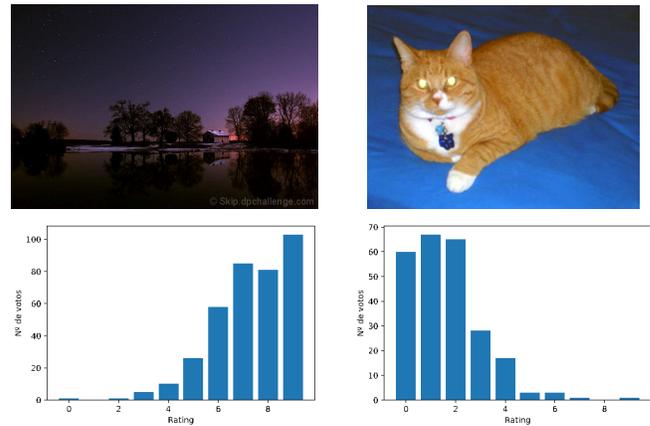


Fig. 3. Ejemplo de una imagen profesional (arriba, izquierda) y de una de mala calidad (arriba, derecha). En la parte inferior se muestra la distribución de los votos para cada imagen.

Generalmente, a partir de los ratings asignados a una imagen, obtenemos estadísticos que nos permiten convertir el problema en uno de clasificación binaria. Por ejemplo, podemos utilizar métricas como la media o la mediana para separar las imágenes en “snapshots” o “professional shots”. Normalmente, se fija un umbral en el punto medio del rango de los ratings, es decir, si los votos van en una escala del 1 al 10, el corte se establece en 5. Finalmente, se obtiene la media para cada imagen  $\mu_i$  a partir de sus votos y se comparan con el umbral. En la Fig 3, en el caso de la izquierda, tenemos una  $\mu = 8.31$ , y en la derecha  $\mu = 2.62$ . Al tener un rango de 10 posibles valores, el umbral se sitúa en el 5, por lo que la imagen de la izquierda sería clasificada como “professional shot” y la de la derecha como “snapshot”.

[10] y [11] proponen resolver el problema con características hechas a mano de bajo nivel para tratar de identificar propiedades más complejas de las fotografías y que sean capaces de separar ambas categorías. Sin embargo, estas propuestas pronto fueron superadas por técnicas generales de extracción de características, como GIST o SIFT [12].

Con la aparición del dataset AVA [13], el problema de la calidad estética ya contaba con una considerable base de datos de imágenes que permitía el aprendizaje de redes de Deep Learning como en [14]. Sin embargo, los resultados de entrenar una red neuronal desde cero, para este problema concreto, no han sido tan relevantes como en otros campos de visión.

[8] demuestra que realizando el proceso de *finetuning* en la última capa de los modelos AlexNet y VGG es posible obtener unos resultados más fiables que los presentados hasta ese momento. [15] también hace uso de esta técnica de Transfer Learning para predecir directamente la distribución de los votos, donde la capa de *output* tiene un tamaño de 10, correspondiente al rango de ratings de AVA, en vez de 2 de la clasificación binaria. En este último caso, en vez de *softmax* como función de activación de la última capa, utilizan Earth Mover’s Distance (EMD), que obtiene la distribución de probabilidad acumulada para la imagen.



Hay que destacar que la mayoría de los trabajos sufrían de un problema con la evaluación, como se indica en [16], ya que la única métrica utilizada en muchas propuestas para validar los modelos era la tasa de aciertos o *accuracy*. En AVA, esta métrica es poco informativa, ya que si binarizamos la clase a partir de los votos, cogiendo como umbral el 5 de media (ya que el rango va de 1 a 10), observamos un desbalanceo de la clase, donde el 70% de los casos son “professional shots” y el 30% “snapshots”. En este caso, reportar una tasa de aciertos del 70% no tiene valor, ya que se pueden estar clasificando todas las imágenes como buenas.

Para resolver esta situación, [16], [8] y [15] hacen uso de diferentes métricas como son el *balanced accuracy* que tiene en cuenta la tasa de aciertos por cada una de las clases o el valor AUC (Area Under the Curve), que relaciona la tasa de Verdaderos Positivos con la tasa de Falsos Positivos. En este trabajo utilizaremos esas métricas cuando trabajemos con problemas desbalanceados.

Es frecuente encontrar en la literatura propuestas que tienden a reducir las bases de datos originales en subconjuntos. Principalmente se eliminan imágenes cuya media de votos se encuentra cerca del umbral de corte. [14] y [12] utilizan una  $\delta$ , de forma que si consideramos 5 el punto de corte, las imágenes  $< 5 - \delta$  son consideradas “snapshots” y las  $> 5 + \delta$  son etiquetadas como “professional shots”, descartando el resto. Otros, como [17] o [18] seleccionan el 10% mejor y peor valoradas y el resto no se tienen en cuenta.

Es comprensible tratar de dar más peso a aquellas imágenes más informativas y tratar de reducir el ruido que pueden generar los casos cercanos a la frontera de decisión. Sin embargo, en algunas de estas propuestas, los resultados presentados han eliminado del conjunto de evaluación las imágenes, con el fin de simplificar el problema. Consideramos que estos resultados no son válidos para un escenario real, donde la mayoría de las imágenes se encuentran cerca del umbral de corte. La eliminación de imágenes sólo debe realizarse en los conjuntos de entrenamiento.

Por último, en las Fig.4 y 5 se muestran resultados preliminares de la evaluación de la calidad estética en AVA utilizando características generales de la imagen. En ambas se refleja la evolución de los resultados en base al valor  $\delta$  donde sólo se descartan las imágenes del conjunto de entrenamiento. Se observa que eliminar las imágenes cercanas al punto de corte no afecta de forma significativa a los resultados, he incluso en el caso del AUC vemos un peor comportamiento. Esto corrobora lo resultados de [14], donde la reducción de las imágenes también perjudica a los modelos de Deep Learning. Por estos motivos, en este trabajo utilizaremos las bases de datos completas.

### III. TRANSFER LEARNING

#### A. Dataset

Actualmente, la base de datos referente para el tratamiento de la calidad estética es AVA. Este dataset esta compuesto por cerca de 250.000 imágenes pertenecientes a una página de retos fotográficos, DPChallenge. Cada foto ha sido valorada

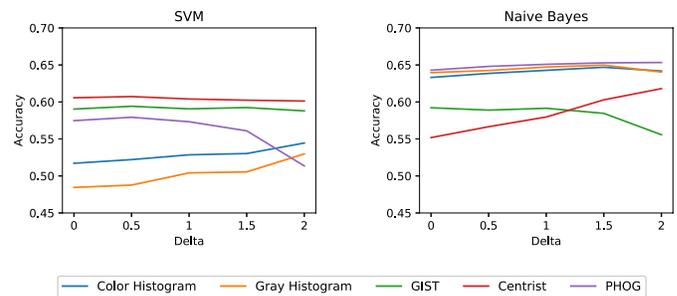


Fig. 4. Evolución del *accuracy* (tasa de aciertos) en base a la  $\delta$  (Delta) para la reducción de imágenes de la base de datos AVA.

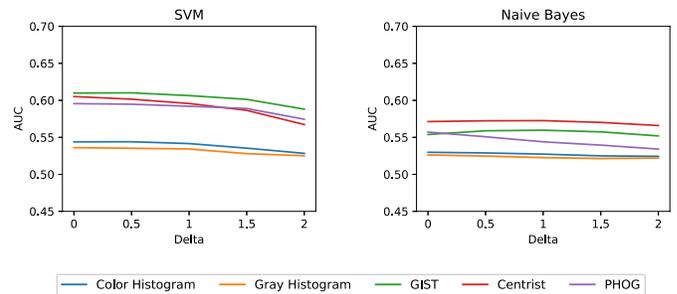


Fig. 5. Evolución del AUC en base a la  $\delta$  (Delta) para la reducción de imágenes de la base de datos AVA.

del 1 al 10 por diferentes usuarios, siendo el 1 que la foto es muy mala y 10 que es muy buena. Además, cada imagen viene etiquetada con el tipo de reto en la que se subió, el estilo fotográfico (si tiene alguno) y ciertas etiquetas sobre objetos que aparecen en la imagen. En los trabajos previos, esta base de datos es particionada en train y test, siendo este último de unas 20k imágenes y las 230k restantes para entrenamiento. En este trabajo utilizaremos la misma partición.

#### B. Extracción de ConvNet features

Durante la evaluación de una imagen en una red neuronal (proceso *forward*), no sólo se obtienen los valores de salida, en cada capa de la red se generan una serie de activaciones que pueden ser extraídas. Aunque es difícil interpretar esta información, puede utilizarse como vectores de características de la imagen, ya que tienen una gran capacidad descriptiva. Esto es lo que se conoce como *ConvNet features* y se utilizan generalmente en problemas donde no tenemos suficientes datos como para entrenar una red neuronal. Estas características son extraídas de redes pre-entrenadas y se utilizan para aprender otros modelos de clasificación.

En [16] se realiza un estudio del rendimiento de las *ConvNet features* extraídas de dos redes neuronales (AlexNet y ResNet) en la evaluación de la calidad estética. En las Fig. 6 y 7 se observan los resultados, donde los modelos entrenados con las *ConvNet features* superaban a los clasificadores que utilizaban descriptores generales de la imagen. Sin embargo, debido a la gran cantidad de características que se obtienen de las redes neuronales, no todos los modelos se muestran en este estudio.

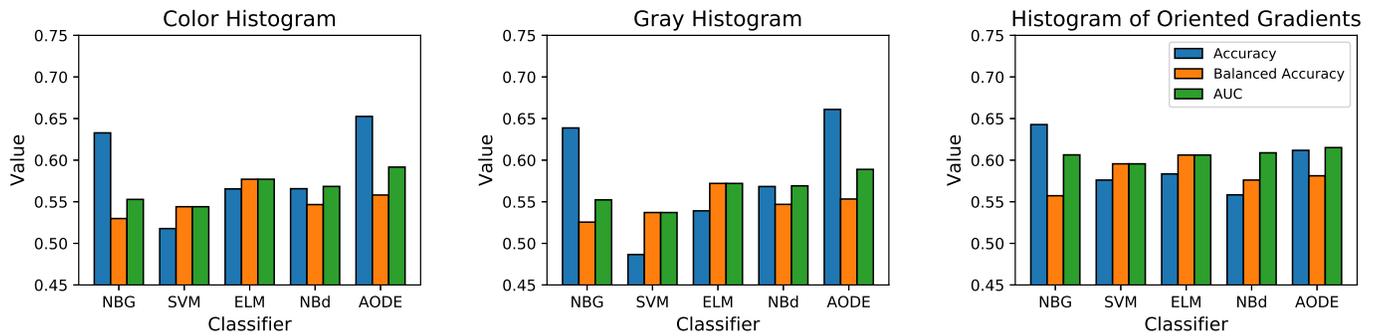


Fig. 6. Resultados de 5 clasificadores entrenados con descriptores generales de la imagen en términos de *accuracy*, *balanced accuracy* y *AUC*.

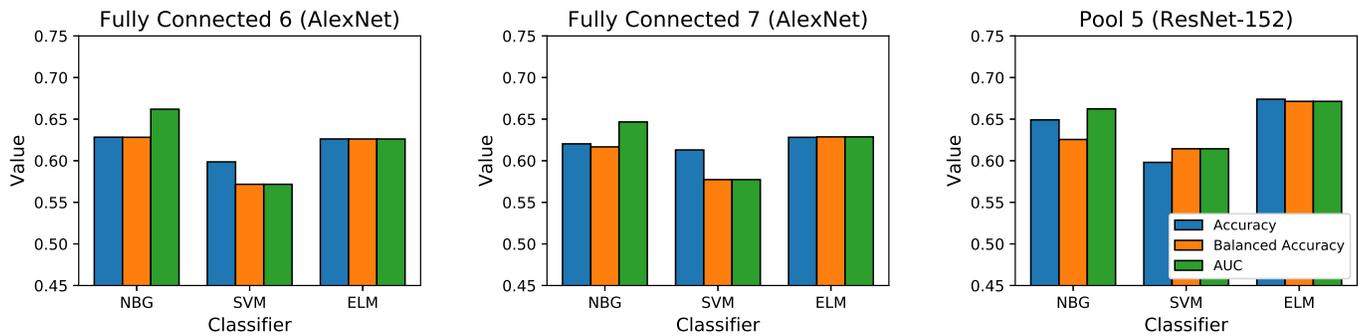


Fig. 7. Resultados de 3 clasificadores entrenados con *ConvNet features* de AlexNet y ResNet en términos de *accuracy*, *balanced accuracy* y *AUC*.

La reducción que vamos a ver a continuación, también tiene el objetivo de disminuir el tamaño de los vectores de características que se extraen de las redes, con el fin de poder utilizar modelos más complejos con esta técnica de Transfer Learning.

### C. Reducción de las capas densas mediante finetuning

Al igual que en la extracción de *ConvNet features*, para el proceso de *finetuning* es necesario disponer de modelos pre-entrenados en problemas similares para utilizar la información en nuestro beneficio.

AlexNet y VGG16 son redes convolucionales que siguen estructuras muy parecidas y que cuyas tres capas finales son del tipo *fully connected* o densas, y la última corresponde con la salida de las 1000 etiquetas del problema de ImageNet. Podemos ver la estructura de ambas redes en las Fig. 8 y 9, respectivamente. Las dos capas densas previas a la salida de la red, son llamadas “fc6” y “fc7”, y tienen dimensiones de 4096 nodos en cada una.

Como se ha comentado antes, la técnica de *finetuning* consiste en realizar modificaciones a una red pre-entrenada, para adaptar la salida del modelo a nuestro problema (Fig. 2). En el caso actual, donde la evaluación de la calidad estética se realiza mediante una clasificación binaria y las redes pre-entrenadas son del problema de ImageNet, sustituimos la capa densa de salida con 1000 nodos por una de 2 nodos.

En los trabajos propuestos que hacen uso de *finetuning*, todas las capas del modelo, exceptuando la de *output*, permanecen inalterables. Sin embargo, consideramos que esta

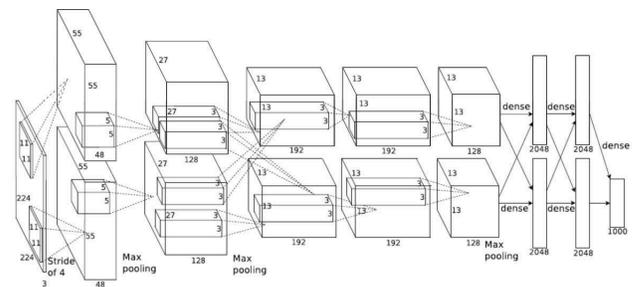


Fig. 8. Estructura original de AlexNet en dos columnas.

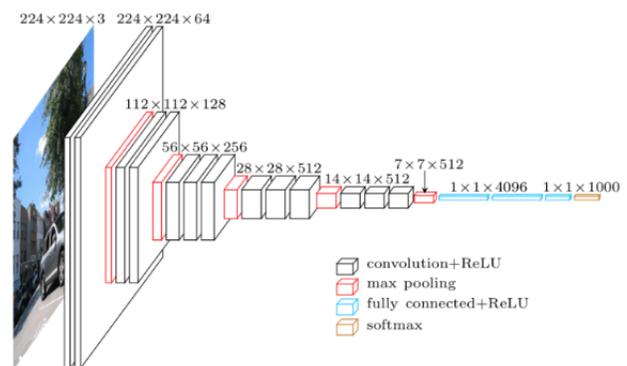


Fig. 9. Estructura de la red VGG16.



Modelo	Nodos en las capas densas	Nº de params de la red	Tamaño del modelo
AlexNet	4096	60M	223MB
	1000	14M	54MB
	500	8,6M	33MB
	250	6,1M	24MB
VGG16	4096	134M	513MB
	1000	41M	156MB
	500	28M	106MB
	250	21M	81M

TABLA I

NÚMERO DE PARÁMETROS (EN MILLONES) DE DIFERENTES REDES Y DEL ESPACIO NECESARIO EN MEMORIA (MEGABYTES) PARA ALMACENARLA, EN FUNCIÓN DEL TAMAÑO DE LAS CAPAS DENSAS.

técnica de Transfer Learning puede utilizarse de forma más eficaz aplicando modificaciones a las capas previas “fc6” y “fc7”, tanto en AlexNet como en VGG16.

En este trabajo, se propone reducir el número de nodos de las tres últimas capas de los modelos AlexNet y VGG16 para resolver la clasificación binaria de la calidad estética. Las capas densas son las que concentran el mayor número de parámetros de una red, por lo que mediante este proceso, disminuiríamos considerablemente el tamaño de la red.

#### D. Implementación

Para este trabajo se ha utilizado la librería TensorFlow [19] en Python para realizar el proceso de *finetuning* a las capas “fc6”, “fc7” y el *output* de las redes neuronales AlexNet y VGG16. En ambos casos se ha utilizado el optimizador SGD (Stochastic Gradient Descent) con un learning rate de 0.001 con un tamaño de batch de 128 y se han realizado 10 epochs. Para las capas de Dropout se ha utilizado un factor de 0,5. Todo esto se ha llevado a cabo sobre una GPU Tesla K40c, donde los tiempos de entrenamiento son de 6-7 horas para AlexNet y de 23 horas para VGG16.

#### IV. RESULTADOS

Se han realizado experimentos reduciendo los nodos de las capas densas “fc6” y “fc7” a 1000, 500 y 250. En la tabla I se muestra la diferencia de tamaño de las redes y la memoria necesaria. Como se puede observar, la mayoría de los parámetros de nuestra red se encuentran en estas capas densas, por lo que al reducir su tamaño afecta significativamente al modelo.

Una vez reentrenadas las redes, vamos a comparar sus resultados utilizando tres métricas de evaluación sobre el conjunto de test. Estas son el *accuracy* o tasa de acierto, el *balanced accuracy* y el valor AUC (Area Under the Curve).

En la tabla II se puede observar que la modificación de las capas densas en AlexNet afecta al *balanced accuracy* y al AUC. Existe un empeoramiento de un 3% del modelo con las capas densas de tamaño 250, frente a las de 4096, pero la red reducida ocupa un 10% de memoria con respecto a la original. Con VGG16 los resultados son casi idénticos en todas las redes, independientemente del tamaño de las capas densas. Cabe destacar que sólo el *accuracy* se ha visto afectado y que

Modelo	Nodos en las capas densas	Accuracy	Balanced Accuracy	AUC
AlexNet	4096	0.70	0.69	0.76
	1000	0.70	0.67	0.74
	500	0.69	0.67	0.73
	250	0.70	0.66	0.73
VGG16	4096	0.70	0.71	0.79
	1000	0.72	0.71	0.79
	500	0.74	0.71	0.79
	250	0.72	0.71	0.79

TABLA II

RESULTADOS EN TÉRMINOS DE ACCURACY, BALANCED ACCURACY Y AUC DE LAS REDES EN BASE AL TAMAÑO DE LAS CAPAS DENSAS.

la red con las capas densas de tamaño 500 funcionan mejor que las originales de 4096.

#### V. CONCLUSIÓN

En este trabajo se ha presentado una estrategia basada en *finetuning* capaz de reducir el tamaño de redes pre-entrenadas, en este caso AlexNet y VGG16, sin perder eficacia en la resolución del problema de la calidad estética.

Hemos visto como podemos obtener los mismos resultados con redes del 10% del tamaño de las propuestas hechas hasta ahora. Esto permitirá que los requisitos para la evaluación de nuevos casos sea mucho menor, permitiendo utilizar dichos modelos en dispositivos como móviles o, por ejemplo, una Raspberry. Estamos seguros de que es un gran paso para el desarrollo de aplicaciones reales que se beneficien del Deep Learning para la evaluación de la calidad estética.

Como trabajo futuro, planeamos seguir optimizando las redes pre-entrenadas en el problema de la calidad estética, especialmente los diseños presentados en [15], donde la salida es la distribución de los votos, en vez de la clasificación binaria en “snapshots” y “professional shots”.

La reducción del número de nodos de las últimas capas de las redes neuronales, además del ahorro de memoria que supone, permite extraer *ConvNet features* con una menor dimensionalidad, pero con la misma capacidad descriptiva. Esto es de especial utilidad para aprender modelos más complejos que antes no podíamos, como por ejemplo, algunos clasificadores probabilísticos, ya que estos modelos manejan de forma natural la incertidumbre y son especialmente útiles en problemas donde la clase no está definida.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado con los fondos FEDER y el Gobierno Español (MICINN) a través del proyecto TIN2016-77902-C3-1-P.

#### REFERENCES

- [1] J. Donahue, Y. Jia, O. Vinyals, J. Hoffman, N. Zhang, E. Tzeng, and T. Darrell, “Decaf: A deep convolutional activation feature for generic visual recognition,” in *International conference on machine learning*, 2014, pp. 647–655.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [3] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.

- [4] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich *et al.*, “Going deeper with convolutions.” *Cvpr*, 2015.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [6] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” *arXiv preprint arXiv:1704.04861*, 2017.
- [7] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, “Imagenet: A large-scale hierarchical image database,” in *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*. IEEE, 2009, pp. 248–255.
- [8] Y. Deng, C. C. Loy, and X. Tang, “Image aesthetic assessment: An experimental survey,” *IEEE Signal Processing Magazine*, vol. 34, no. 4, pp. 80–106, 2017.
- [9] R. Datta, J. Li, and J. Z. Wang, “Algorithmic infereencing of aesthetics and emotion in natural images: An exposition,” in *Image Processing, 2008. ICIP 2008. 15th IEEE International Conference on*. IEEE, 2008, pp. 105–108.
- [10] R. Datta, D. Joshi, J. Li, and J. Z. Wang, “Studying aesthetics in photographic images using a computational approach,” in *European Conference on Computer Vision*. Springer, 2006, pp. 288–301.
- [11] Y. Ke, X. Tang, and F. Jing, “The design of high-level features for photo quality assessment,” in *Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference on*, vol. 1. IEEE, 2006, pp. 419–426.
- [12] L. Marchesotti, F. Perronnin, D. Larlus, and G. Csurka, “Assessing the aesthetic quality of photographs using generic image descriptors,” in *Computer Vision (ICCV), 2011 IEEE International Conference on*. IEEE, 2011, pp. 1784–1791.
- [13] N. Murray, L. Marchesotti, and F. Perronnin, “Ava: A large-scale database for aesthetic visual analysis,” in *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*. IEEE, 2012, pp. 2408–2415.
- [14] X. Lu, Z. Lin, H. Jin, J. Yang, and J. Z. Wang, “Rapid: Rating pictorial aesthetics using deep learning,” in *Proceedings of the 22nd ACM international conference on Multimedia*. ACM, 2014, pp. 457–466.
- [15] H. Talebi and P. Milanfar, “Nima: Neural image assessment,” *IEEE Transactions on Image Processing*, vol. 27, no. 8, pp. 3998–4011, 2018.
- [16] F. Rubio, M. J. Flores, and J. M. Puerta, “Drawing a baseline in aesthetic quality assessment,” in *Tenth International Conference on Machine Vision (ICMV 2017)*, vol. 10696. International Society for Optics and Photonics, 2018, p. 106961M.
- [17] X. Tian, Z. Dong, K. Yang, and T. Mei, “Query-dependent aesthetic model with deep learning for photo quality assessment,” *IEEE Transactions on Multimedia*, vol. 17, no. 11, pp. 2035–2048, 2015.
- [18] Z. Dong, X. Shen, H. Li, and X. Tian, “Photo quality assessment with dcnn that understands image well,” in *International Conference on Multimedia Modeling*. Springer, 2015, pp. 524–535.
- [19] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng, “TensorFlow: Large-scale machine learning on heterogeneous systems,” 2015, software available from tensorflow.org. [Online]. Available: <https://www.tensorflow.org/>



# Redes Neuronales Convolucionales para Una Clasificación Precisa de Imágenes de Corales

Anabel Gómez-Ríos, Siham Tabik, Julián Luengo and Francisco Herrera  
 Dpto. Ciencias de la Computación e Inteligencia Artificial  
 Universidad de Granada  
 Granada, España  
 {anabelgrios, julianlm, herrera}@decsai.ugr.es, siham@ugr.es

ASM Shihavuddin  
 Dpto. Matemática Aplicada y Ciencias de la Computación  
 Universidad Técnica de Dinamarca  
 Kgs. Lyngby, Dinamarca

Bartosz Krawczyk  
 Dpto. Ciencias de la Computación  
 Universidad Virginia Commonwealth  
 Virginia, EEUU

**Resumen**—El reconocimiento de especies de corales basado en imágenes submarinas de texturas plantea una gran dificultad para los algoritmos de aprendizaje automático, debido a la naturaleza de los datos y las características que tienen. Entre otras, encontramos que los conjuntos de datos no incluyen información sobre la estructura global del coral, que muchas especies de coral tienen características muy similares y que definir los límites espaciales entre clases es difícil ya que muchos corales tienden a vivir juntos. Por ello, la clasificación de especies de corales siempre ha requerido de la ayuda de un experto. El objetivo de este trabajo es desarrollar un modelo de clasificación precisa para imágenes de textura de corales. Nos hemos centrado en dos conjuntos de datos de imágenes de texturas y hemos analizado 1) varias arquitecturas de redes neuronales convolucionales, 2) *transfer learning* y 3) técnicas de *data augmentation*. Hemos alcanzado los porcentajes de clasificación más altos usando diferentes variaciones de ResNet en ambos conjuntos de datos.

**Index Terms**—Redes Neuronales Convolucionales, Clasificación, Imágenes de Corales, Inception, ResNet, DenseNet

## I. INTRODUCCIÓN

Los arrecifes de coral son ecosistemas marinos típicos de los mares cálidos y poco profundos de los trópicos. Se crean por la acumulación de esqueletos de carbonato de calcio que las especies de coral duro dejan cuando mueren. Otros corales viven después en ellos y expanden el arrecife. Son uno de los ecosistemas más valiosos del mundo al ser extremadamente biodiversos. Soportan hasta dos millones de especies y una cuarta parte de toda la vida marina en el mundo [1]. Son también muy importantes desde el punto de vista humano [2]: ayudan a limpiar el agua eliminando el nitrógeno y el carbono, son una fuente de investigación médica y económica a partir de la pesca y el turismo, una barrera natural contra huracanes y tormentas y su estudio ayuda a comprender fenómenos climáticos del pasado debido a la cantidad de años que tienen.

Este trabajo ha sido realizado con el apoyo del Ministerio de Ciencia y Tecnología de España bajo el proyecto TIN2017-89517-P y de la Junta de Andalucía bajo el proyecto P11-TIC-7765. Siham Tabik cuenta con una beca del programa Ramón y Cajal (RYC-2015-18136) y Anabel Gómez-Ríos con una beca FPU 998758-2016.

El estudio de la distribución de los arrecifes de coral a lo largo del tiempo provee información sobre el impacto del calentamiento global y los niveles de contaminación del agua. Según [1], ya se ha perdido el 19 % del área de arrecifes de coral desde la década de 1950 y, según la Unión Internacional para la Conservación de la Naturaleza (IUCN por sus siglas en inglés) y su Lista Roja de Especies Amenazadas [3], en 2017 había 237 especies amenazadas sólo en el evaluado 40 % del total estimado de especies. Esto se debe en gran medida a problemas causados por humanos: la contaminación del agua, el cambio climático, ya que los corales no toleran los cambios de temperatura, y el dióxido de carbono emitido a la atmósfera, donde un cuarto es absorbido por el océano.

Con los avances en la adquisición de imágenes y el creciente interés de la comunidad científica, se están recolectando una gran cantidad de datos sobre corales. Sin embargo, es complicado llevar un registro de todas las especies porque hay miles de ellas y la taxonomía es mutable debido a nuevos descubrimientos o por cambios en las especies conocidas a medida que se adquiere más conocimiento sobre ellas. Además, algunas especies de coral pueden parecer idénticas entre ellas para un observador humano. Por esto, se ha necesitado siempre de un experto biólogo para obtener una buena clasificación. Si conseguimos automatizar esta clasificación usando la cantidad de imágenes de corales que se están recogiendo, podemos ayudar a los científicos a estudiar más de cerca esa cantidad de datos. De hecho, la automatización de la clasificación de imágenes de corales se ha abordado en algunos trabajos. La mayoría de ellos [4], [5], [6], [7] usan modelos de aprendizaje automático combinados con técnicas de mejora de imagen y varios extractores de características. Entre estos trabajos, sólo [6] utiliza varios conjuntos de datos.

En los últimos años, las redes neuronales convolucionales (CNNs por sus siglas en inglés) han mostrado una precisión excepcional para la clasificación de imágenes [8], [9], especialmente en el campo de la visión por computador. Actualmente, sus aplicaciones se extienden a muchos campos

en los que se requiere un análisis de imágenes. El uso de CNNs en clasificación de corales supone un reto por varias causas: las diferencias entre imágenes de la misma clase, las variaciones de luz debidas al agua o el hecho de que algunas especies de coral tienden a aparecer juntas. Por otra parte, las CNNs necesitan grandes conjuntos de datos para lograr un buen rendimiento. En la práctica, se usan dos técnicas para sobrevenir esta limitación: *transfer learning*, que consiste en usar el conocimiento obtenido de otro problema, usualmente más grande, y *data augmentation*, que consiste en aumentar artificialmente el conjunto de datos de entrenamiento. Hay algunos trabajos que utilizan CNNs para clasificación de corales [10], [11], [12], pero evalúan CNNs más simples, como VGGnet o LeNet y sólo usan un conjunto de datos.

En este trabajo se propone utilizar CNNs más nuevas y con mayor capacidad para superar las limitaciones de las CNNs que se han usado anteriormente. Queremos desarrollar un sistema más preciso que se enfrente a los problemas específicos de la clasificación de imágenes de corales usando varios conjuntos de datos. En particular, hemos considerado tres de las CNN más prometedoras, Inception v3 [13], ResNet [14] y DenseNet [15]. Inception es una nueva versión de GoogleNet [16], que ganó el premio *ImageNet Large Scale Visual Recognition Competition (ILSVRC)* [9] en 2014. ResNet ganó la misma competición en 2015 y DenseNet mejoró los resultados de ResNet en 2016. Para la clasificación, hemos considerado dos conjuntos de imágenes submarinas de corales, RSMAS y EILAT [17], que tienen la particularidad de que muestran texturas de corales, no los corales completos. Además, son conjuntos de datos pequeños que contienen muchas clases. Por otra parte, hemos comparado nuestros resultados con el modelo actual más preciso para estos dos conjuntos de datos, el propuesto por Shihavuddin y otros en [6], el cual está compuesto por distintos algoritmos clásicos de aprendizaje automático y requiere una gran supervisión.

Las contribuciones de este trabajo son las siguientes:

- Analizar las tres CNNs que hemos evaluado en este trabajo: Inception v3, ResNet y DenseNet.
- Evaluar estas tres CNNs y analizar su rendimiento usando *transfer learning* desde ImageNet.
- Analizar distintas técnicas de *data augmentation* en este tipo concreto de imágenes.
- Comparar nuestros resultados con el actual estado del arte en EILAT y RSMAS.

El resto del trabajo está organizado de la siguiente forma: en la Sección II estudiamos y analizamos Inception, ResNet y DenseNet. En la Sección III se comentan los avances que se han hecho en la clasificación de corales basada en imágenes. En la Sección IV se exponen las características de los conjuntos de datos que se han usado en este trabajo. En la Sección V se exponen y analizan los resultados que se han obtenido con los distintos modelos de CNN y tipos de *data augmentation*. Finalmente, en la Sección VI se muestran las conclusiones obtenidas y los trabajos futuros.

## II. CONVOLUTIONAL NEURAL NETWORKS

Las CNNs han logrado precisiones excepcionales en varias aplicaciones actuales [18]. De hecho, desde 2012 la prestigiosa competición ILSVRC [9] sólo la han ganado CNNs. Las capas de una CNN capturan características cada vez más complejas a medida que aumenta la profundidad de la red. En los últimos años, estas arquitecturas han ido evolucionado, primero incrementando la profundidad de las redes, después el ancho y finalmente usando características obtenidas en las primeras capas inferiores en capas más profundas. Esta sección proporciona una visión general de las CNNs utilizadas en este trabajo. Hemos considerado tres CNNs influyentes, Inception v3 (Subsección II-A), ResNet (Subsección II-B) y DenseNet (Subsección II-B). Estas tres CNNs se basan en la repetición de un módulo o bloque base compuesto por una serie de capas convolucionales, de *poolings* o de capas de normalización. La diferencia entre ellas es la composición de los módulos y cómo están distribuidos dentro de la red. Para finalizar, describimos las técnicas de optimización que hemos usado para paliar el problema de los conjuntos de datos pequeños, *transfer learning* y *data augmentation* (Subsección II-D).

### II-A. Inception v3

El módulo base de Inception [13] consta de cuatro ramas en paralelo: una convolución de kernel  $1 \times 1$  seguida de dos convoluciones  $3 \times 3$ , una convolución  $1 \times 1$  seguida de una convolución  $3 \times 3$ , un *pooling* seguido de una convolución  $1 \times 1$  y por último una convolución  $1 \times 1$ . La salida del módulo es la concatenación de las cuatro ramas. Inception consta en total de 10 módulos, aunque dichos módulos se van modificando ligeramente según la red se va haciendo más profunda. En concreto, se cambian cinco de los módulos con el fin de reducir el coste computacional sustituyendo las convoluciones  $n \times n$  por dos convoluciones, una  $1 \times 7$  seguida de una  $7 \times 1$ . Los dos últimos módulos sustituyen las dos últimas convoluciones  $3 \times 3$  de la primera rama por dos convoluciones cada una, una  $1 \times 3$  seguida de otra  $3 \times 1$ , esta vez en paralelo. En total, Inception v3 tiene 42 capas con parámetros.

### II-B. ResNet

ResNet [14] no tiene una profundidad fija y depende del número de módulos consecutivos que se usen. Sin embargo, aumentar la profundidad de la red para obtener una mayor precisión hace que la red sea más difícil de optimizar ya que es más fácil que se produzca el problema de la desaparición de gradientes. ResNet aborda este problema ajustando una aplicación residual en lugar de la original, y añadiendo varias conexiones entre capas. Estas nuevas conexiones saltan varias capas y realizan una identidad o una convolución  $1 \times 1$ . El bloque base de esta red se llama *residual block* y está compuesto, cuando la red tiene 50 o más capas, por tres convoluciones secuenciales, una  $1 \times 1$ , una  $3 \times 3$  y una  $1 \times 1$ , y una conexión que une la entrada de la primera convolución a la salida de la tercera convolución. En nuestro caso hemos usado dos modelos con esta arquitectura, ResNet-50, compuesta por 50 capas y ResNet-152, compuesta por 152 capas.



## II-C. DenseNet

DenseNet [15] tampoco tiene una profundidad fija y depende del número de módulos que se usen. En este caso el módulo o bloque se llama *dense block* y como el de ResNet, introduce conexiones entre capas no consecutivas. En este caso, se conecta la salida de todas las capas dentro del *dense block* a la entrada de todas las capas siguientes dentro del bloque. Las conexiones entre bloques, llamadas capas de transición, funcionan como un factor de compresión en el sentido de que generan menos mapas de características de los que reciben. El bloque está compuesto de una repetición de las siguientes operaciones: *Batch Normalization* (BN), ReLU, convolución  $1 \times 1$ , BN, ReLU y convolución  $3 \times 3$ . Las capas de transición son una convolución  $1 \times 1$  seguida de un *average pooling* con kernel  $2 \times 2$ . En este trabajo, hemos analizado DenseNet-121 y DenseNet-161, que incluyen 121 y 161 capas.

## II-D. Técnicas de Optimización de CNNs

Todas las redes anteriores son demasiado profundas como para entrenarlas desde cero con nuestros conjuntos de datos, ambos muy pequeños. Por ello, hemos usado las técnicas de *transfer learning* y *data augmentation*.

La técnica de *transfer learning* consiste en usar el conocimiento aprendido de otro problema, generalmente más grande, comenzando el entrenamiento de los pesos, en lugar de con valores aleatorios, con los pesos entrenados con otro problema. En concreto, nosotros hemos usado las redes preentrenadas con ImageNet [19], y como los conjuntos de datos siguen siendo demasiado pequeños, en lugar de ajustar todos los pesos de las redes hemos añadido dos capas completamente conectadas al final de las redes anteriores. La primera de estas dos capas tiene 512 neuronas y una activación ReLU y la última tiene tantas neuronas como clases tiene el conjunto de datos que queremos clasificar y una activación softmax. De esta forma sólo entrenamos estas nuevas dos capas.

La técnica de *data augmentation* [20] consiste en aumentar artificialmente el conjunto de entrenamiento aplicando varias transformaciones a las imágenes originales, como cambiar el brillo, escalarlas, acercarlas, girarlas, reflejarlas verticalmente, etc. Las nuevas imágenes deben ser lo suficientemente reales como para que un observador externo no sepa distinguir una imagen generada por *data augmentation* de una original. En nuestro caso hemos aplicado las siguientes transformaciones:

- Desplazamiento: consiste en desplazar las imágenes horizontal y verticalmente un número determinado de píxeles calculado como una fracción del ancho o alto de la imagen. Dicha fracción se elige aleatoriamente en cada caso en el intervalo  $[0, x]$  para un  $x$  dado.
- Zoom: consiste en acercar o alejar las imágenes. Dado un valor  $x$ , cada imagen será redimensionada a un valor aleatorio en el intervalo  $[1 - x, 1 + x]$ .
- Rotación: consiste en rotar aleatoriamente las imágenes un ángulo determinado. Dado un valor  $x$ , cada imagen se rotará un ángulo aleatorio en el intervalo  $[0, x]$ .
- Reflejar: consiste en reflejar las imágenes horizontalmente de forma aleatoria.

## III. AVANCES EN LA CLASIFICACIÓN DE IMÁGENES DE CORALES

En esta sección comentamos los avances previos que ha habido en la clasificación automática de imágenes de corales, mostrando los retos que conlleva dicha clasificación (Subsección III-A) y los trabajos que la han analizado previamente (Subsección III-B).

### III-A. Retos en la Clasificación de Imágenes de Corales

La clasificación de especies de corales basada en imágenes de texturas de corales es compleja por las siguientes razones:

- Oclusión parcial de objetos y animales.
- Variaciones en la luz debido al movimiento de mareas y a las propiedades ópticas del agua. Es común que la única fuente de luz sea la de la cámara, lo que implica iluminación no uniforme en las imágenes obtenidas.
- Anotación subjetiva de los conjuntos de datos por diferentes expertos.
- Variación en puntos de vista, distancias y calidad de imagen.
- Variabilidad en la morfología de corales que pertenecen a la misma especie.
- Separación entre clases compleja, ya que distintas especies de corales tienden a aparecer juntas.

### III-B. Trabajos Relacionados

Los trabajos previos en la clasificación de imágenes de corales se pueden dividir en dos grupos: métodos que combinan algoritmos clásicos del aprendizaje automático con algoritmos de extracción de características y métodos que usan CNNs.

La mayoría de los enfoques existentes para clasificar las imágenes de corales combinan un extractor de características con un clasificador y muestran su rendimiento utilizando un único conjunto de datos [4], [5], [7]. En el primer trabajo sobre este tema [5], los autores analizaron más hábitat marino además de corales. Utilizaron un descriptor SIFT y un modelo de bolsa de características, consistente en elegir del conjunto de entrenamiento las imágenes que son más similares a cada imagen de test. En [4] se introduce el conjunto de datos *Moorea Labeled Corals* (MLC), que contiene imágenes de gran tamaño de diferentes especies de coral, y se usa SVM junto con filtros y un descriptor de textura para clasificarlo. Obtuvieron una precisión del 83,1% sobre este conjunto de datos utilizando las imágenes de 2008 y 2009 para entrenamiento y las imágenes de 2010 para test. En [7] se utilizó un espacio de color normalizado y la transformación discreta del coseno como descriptor de textura. Sólo utilizaron un conjunto de datos, proporcionado por el *National Oceanic and Atmospheric Administration* (NOAA) del Departamento de Comercio de EE.UU.

Estos métodos no se han probado aún con nuevos conjuntos de datos. Sólo Shihavuddin y otros [6] desarrollaron un algoritmo de clasificación unificado para varios conjuntos de datos de características diferentes, entre los que podemos encontrar a RSMAS y EILAT. Los autores combinaron múltiples técnicas

de mejora de imágenes, extractores de características y clasificadores en un modelo compuesto de seis pasos. Cada paso se compone de varios algoritmos que pueden ser obligatorios u opcionales. La clasificación se realiza usando SVM, KNN, una red neuronal o la distancia media ponderada por la densidad de probabilidad. Configurando los hiperparámetros de los algoritmos y las diferentes combinaciones entre ellos, el modelo puede adaptarse a los diferentes conjuntos de datos. Este método es el estado del arte para RSMAS y EILAT. Sin embargo, implica mucha supervisión, ya que es necesario evaluar todas las combinaciones posibles de algoritmos y los hiperparámetros de cada uno de ellos.

Por otro lado, hay varios trabajos que usan CNNs. El primero de ellos fue [10]. El autor mejoró primero las imágenes de entrada mediante corrección del color y un filtrado de suavidad de la imagen para después entrenar un modelo basado en LeNet-5 en el que la capa de entrada consistía en tres canales para una imagen en color y canales adicionales para descriptores de textura y forma.

El siguiente trabajo que usó CNNs fue [11], donde los autores utilizaron VGGnet ya entrenada en ImageNet y el conjunto de datos BENTHOZ-2015 [21] para seguir entrenando la red. BENTHOZ-2015 contiene más de 400,000 imágenes y datos de sensores asociados recogidos por un vehículo autónomo sobre Australia. Los autores extrajeron varios trozos de cada imagen centrados en diferentes píxeles usando diferentes escalas. Propusieron un mecanismo para etiquetar automáticamente las imágenes de corales de forma que se obtuviera la cobertura de los corales en la región donde se recolectaron las imágenes (clasificando las nuevas imágenes como coral o no).

Por último, en [12] los autores utilizaron el conjunto de datos MLC y usaron CNNs junto con características extraídas de las imágenes, introduciendo un nuevo mecanismo para extraerlas. Se basaron en que las CNNs no pueden ser entrenadas desde cero usando los conjuntos de datos de corales disponibles debido a su pequeño tamaño. La extracción de características con CNNs se realizó con la red VGGnet preentrenada en ImageNet. Para clasificar ambos tipos de características, utilizaron un Perceptrón de dos capas. En sus experimentos, obtuvieron mejores precisiones con esta técnica que sólo con VGGnet, aunque la diferencia era pequeña.

Estos trabajos usan CNNs clásicas, como VGGnet o LeNet, y no usan EILAT ni RSMAS. Además, los resultados obtenidos son bajos [10], la clasificación es demasiado simple [11] o combinan las redes con otras características [12].

#### IV. CONJUNTOS DE DATOS

En este trabajo, hemos utilizado los conjuntos de datos RGB más recientes y pequeños que contienen el mayor número de especies de coral, RSMAS y EILAT [17]. Estos dos conjuntos de datos se componen de imágenes que muestran trozos de corales. Estos trozos capturan la textura de diferentes partes del coral y no incluyen información sobre la estructura global del mismo. Sus principales características son las siguientes:

- EILAT contiene 1123 imágenes de tamaño  $64 \times 64$ , tomadas de arrecifes de coral cerca de Eilat en el Mar Rojo.

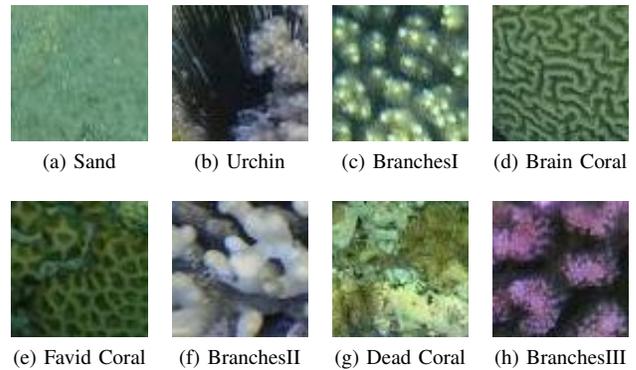


Figura 1. Un ejemplo de cada clase de EILAT.

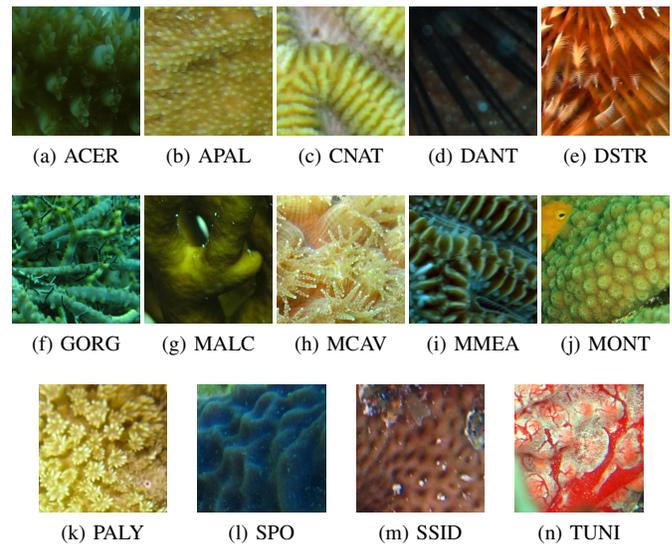


Figura 2. Un ejemplo de cada clase de RSMAS.

Estas imágenes son trozos de imágenes más grandes, que fueron tomadas en iguales condiciones y con la misma cámara fotográfica. Las imágenes han sido clasificadas en ocho clases, pero las etiquetas utilizadas no corresponden a los nombres de las especies de coral. En la Fig. 1 podemos ver ejemplos de este conjunto de datos.

- RSMAS contiene 766 imágenes de tamaño  $256 \times 256$ . Las imágenes fueron recogidas por buzos de la Escuela Rosenstiel de Ciencias Marinas y Atmosféricas de la Universidad de Miami. Fueron tomadas bajo diferentes condiciones, con diferentes cámaras y en lugares diferentes. Las imágenes se han clasificado en 14 clases, cuyas etiquetas corresponden a los nombres en latín de la especie de coral que se muestra en cada clase. En la Fig. 2 podemos ver ejemplos de este conjunto de datos.

#### V. CLASIFICACIÓN DE IMÁGENES DE CORALES USANDO CNNs

Esta sección está organizada en tres partes. Primero, mostramos el marco experimental que hemos usado en todos los ex-



perimentos llevados a cabo en este trabajo (Subsección V-A). Después, mostramos y analizamos los resultados de la clasificación de EILAT y RSMAS usando sólo *transfer learning* (Subsección V-B). Por último, mostramos y analizamos los resultados de las distintas técnicas de *data augmentation* en la clasificación usando el mejor modelo en cada caso hallado en la Subsección V-B (Subsección V-C).

#### V-A. Marco Experimental

Para evaluar todas las CNNs, hemos usado Keras [22] y Tensorflow [23] como *back-end*. Para Inception hemos usado la implementación disponible en la versión 2.0.4 de Keras y para ResNet y DenseNet, hemos adaptado el código disponible en GitHub por [24]. Todas han sido evaluadas en una gráfica NVIDIA Titan Xp.

Para la evaluación, hemos usado la medida *accuracy*, es decir, el porcentaje de acierto en la clasificación, y un esquema de validación cruzada con cinco particiones, por lo que todos los resultados que se dan en esta sección son la media de los porcentajes obtenidos sobre las cinco particiones.

Además, hemos evaluado el impacto de distintos hiperparámetros en el rendimiento de las redes, como el número de capas, el número de épocas que las entrenamos y el tamaño del *batch* que usamos para entrenarlas. En concreto, hemos usado 50 y 152 capas con ResNet, y 121 y 161 con DenseNet, con lo que tenemos cinco modelos de CNNs. Para cada uno de estos modelos, hemos probado todas las combinaciones posibles de los valores para los hiperparámetros número de épocas = {100, 300, 500, 700, 1000, 1300} y *batch* = {32, 64, 128}.

#### V-B. Clasificación Usando Transfer Learning

En esta subsección analizamos el comportamiento de las redes con *transfer learning* desde ImageNet. Hemos evaluado todas las combinaciones de los hiperparámetros comentados en la subsección anterior y en la Tabla I se muestran aquellos con los que se han obtenido los mejores resultados para cada modelo junto con el *accuracy* correspondiente para dicha combinación. Se muestra además el resultado para el método de Shihavuddin, el estado del arte para estos dos conjuntos de datos. Como vemos, ResNet-152 supera al método de Shihavuddin y al resto de las CNN. Inception proporciona un mejor *accuracy* que el método de Shihavuddin en RSMAS, pero es peor en EILAT. DenseNet muestra los peores resultados en ambos conjuntos de datos. En general, estos resultados muestran que las CNNs son capaces de convertirse en el estado del arte en tareas de clasificación de corales. En RSMAS, el mejor modelo es ResNet-152, con una mejora de más del 5% con respecto al método de Shihavuddin. En EILAT, ResNet-50 y ResNet-152 alcanzan exactamente el mismo *accuracy* y superan al método de Shihavuddin en más de un 2%.

Los resultados obtenidos permiten concluir que sólo entrenando las últimas capas de una CNN que ya está preentrenada en ImageNet podemos superar a un método que requiere mucho tiempo y una alta supervisión humana como es el método de Shihavuddin, que se compone de seis pasos y cada paso se compone de varios algoritmos, de forma que para

obtener el mejor rendimiento es necesario evaluar todas las combinaciones de algoritmos posibles a través de todos los pasos y optimizar los hiperparámetros de cada algoritmo.

#### V-C. Clasificación Usando Data Augmentation

En esta subsección analizamos el impacto de las técnicas de *data augmentation* enumeradas en la Subsección II-D. Tanto para EILAT como para RSMAS hemos evaluado dichas técnicas sobre los modelos que obtenían mejor rendimiento en cada caso. Para EILAT hemos usado ResNet-50 por ser más simple que ResNet-152 y obtener ambos el mismo *accuracy*. Para RSMAS hemos usado ResNet-152.

La notación `rot. = 2` significa que estamos aplicando una rotación a cada imagen de un ángulo elegido aleatoriamente para cada una en el intervalo  $[0, 2]$ . Esta notación es equivalente para el resto de técnicas.

La Tabla II muestra los resultados de usar *data augmentation* con ResNet-50 en EILAT y la Tabla III muestra los resultados de ResNet-152 en RSMAS. Hemos evaluado diferentes parámetros para cada técnica y varias combinaciones entre ellas, aunque en las tablas sólo se muestran las que obtuvieron un mejor resultado en cada caso. En ambos casos, la diferencia en *accuracy* entre no usar *data augmentation* y la mejor de las técnicas es muy pequeña, menos del 1%.

La poca mejora obtenida puede explicarse por la naturaleza de las imágenes utilizadas. Dado que las imágenes originales son pequeñas y están tomadas muy de cerca, las modificaciones que aplicamos tienen que ser muy pequeñas y por tanto no tienen mucho efecto en el aprendizaje de los modelos: el desplazamiento implica perder parte de unas imágenes que ya son pequeñas y el acercamiento o zoom implica perder calidad y partes de las imágenes. Además, las imágenes están tomadas tan de cerca que la rotación y el giro no introducen variaciones significativas. Por otra parte, el rendimiento de los modelos sin usar *data augmentation* es bastante bueno, por lo que es más difícil mejorarlo.

## VI. CONCLUSIONES

La clasificación de imágenes submarinas de corales es difícil debido a la gran cantidad de especies de coral que existen, las grandes diferencias entre imágenes de una misma especie, las variaciones de luz debido al agua, o el solapamiento existente entre diferentes clases. Pocos trabajos han abordado este problema, y el único que clasifica EILAT y RSMAS es un método complejo que utiliza varios algoritmos y necesita de mucho tiempo e intervención.

Nosotros hemos abordado estos problemas utilizando algunas de las CNNs más potentes, Inception v3, ResNet y DenseNet. Hemos realizado un estudio de los fundamentos de estas CNNs, sus hiperparámetros y la posibilidad de utilizar *transfer learning* y *data augmentation*. De esta forma, hemos sido capaces de mejorar el estado del arte en EILAT y RSMAS, demostrando que las CNNs son una excelente técnica para la clasificación automática de imágenes submarinas de corales. En particular, ResNet ha sido la mejor CNN tanto en EILAT como en RSMAS.

Tabla I

MEJOR ACCURACY, Y EL CONJUNTO DE HIPERPARÁMETROS QUE LO PROVEE EN CADA CASO, OBTENIDO POR INCEPTION V3, RESNET-50, RESNET-152, DENSENET-121, DENSENET-161 Y EL MODELO DE SHIHAVUDDIN. EL MEJOR RESULTADO ESTÁ RESALTADO EN NEGRITA.

		Método de Shihavuddin	Inception v3	ResNet-50	ResNet-152	DenseNet-121	DenseNet-161
EILAT	Accuracy	95.79	96.23	<b>97.85</b>	<b>97.85</b>	91.03	93.81
	Batch	—	32	<b>64</b>	<b>64</b>	32	32
	Épocas	—	700	<b>500</b>	<b>300</b>	300	700
RSMAS	Accuracy	92.74	96.71	97.67	<b>97.95</b>	89.73	91.10
	Batch	—	32	64	<b>32</b>	32	64
	Épocas	—	1300	1300	<b>300</b>	700	1000

Tabla II

MEJORES ACCURACIES OBTENIDAS POR RESNET-50 EN EILAT CON SUS MEJORES PARÁMETROS USANDO DISTINTAS TÉCNICAS DE DATA AUGMENTATION. EL MEJOR RESULTADO ESTÁ RESALTADO EN NEGRITA.

	despl. = 0.2	acer. = 0.2	rot. = 2	refl.	despl. = 0.2, acer. = 0.2
Acc.	<b>98.03</b>	97.85	97.40	97.53	97.85

Tabla III

MEJORES ACCURACIES OBTENIDAS POR RESNET-152 EN RSMAS CON SUS MEJORES PARÁMETROS USANDO DISTINTAS TÉCNICAS DE DATA AUGMENTATION. EL MEJOR RESULTADO ESTÁ RESALTADO EN NEGRITA.

	despl. = 0.2	acer. = 0.4	rot. = 2	refl.	despl. = 0.2, acer. = 0.4
Acc.	98.36	<b>98.63</b>	97.40	97.578	98.08

Mientras que el uso de *transfer learning* sí ha dado resultados muy buenos, el uso de técnicas de *data augmentation* en este tipo de imágenes no introduce una mejora significativa en los modelos.

Este trabajo abre nuevos retos como la clasificación de especies de corales basándonos no sólo en imágenes de texturas, sino también en imágenes que contengan la estructura completa de los corales.

## REFERENCIAS

- [1] ESI, “Endangered species international.” <http://www.endangeredspeciesinternational.org/>, 2017. Accessed on 13-02-2018.
- [2] F. Ferrario, M. W. Beck, C. D. Storlazzi, F. Micheli, C. C. Shepard, and L. Airolidi, “The effectiveness of coral reefs for coastal hazard risk reduction and adaptation,” *Nature communications*, vol. 5, p. 3794, 2014.
- [3] IUCN, “Iucn red list table of number of threatened species by major groups of organisms.” [http://cmsdocs.s3.amazonaws.com/summarystats/2017-3\\_Summary\\_Stats\\_Page\\_Documents/2017\\_3\\_RL\\_Stats\\_Table\\_1.pdf](http://cmsdocs.s3.amazonaws.com/summarystats/2017-3_Summary_Stats_Page_Documents/2017_3_RL_Stats_Table_1.pdf), 2017. Accessed on 13-02-2018.
- [4] O. Beijbom, P. J. Edmunds, D. I. Kline, B. G. Mitchell, and D. Kriegman, “Automated annotation of coral reef survey images,” in *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, pp. 1170–1177, IEEE, 2012.
- [5] O. Pizarro, P. Rigby, M. Johnson-Roberson, S. B. Williams, and J. Colquhoun, “Towards image-based marine habitat classification,” in *OCEANS 2008*, pp. 1–7, IEEE, 2008.
- [6] A. Shihavuddin, N. Gracias, R. Garcia, A. C. Gleason, and B. Gintert, “Image-based coral reef classification and thematic mapping,” *Remote Sensing*, vol. 5, no. 4, pp. 1809–1841, 2013.
- [7] M. D. Stokes and G. B. Deane, “Automated processing of coral reef benthic images,” *Limnol. Oceanogr.: Methods*, vol. 7, no. 157, pp. 157–168, 2009.
- [8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, pp. 1097–1105, 2012.
- [9] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg, and L. Fei-Fei, “Imagenet Large Scale Visual Recognition Challenge,” *International Journal of Computer Vision (IJCV)*, vol. 115, no. 3, pp. 211–252, 2015.
- [10] M. Elawady, “Sparse coral classification using deep convolutional neural networks,” *arXiv preprint arXiv:1511.09067*, 2015.
- [11] A. Mahmood, M. Bennamoun, S. An, F. Sohel, F. Boussaid, R. Hovey, G. Kendrick, and R. Fisher, “Automatic annotation of coral reefs using deep learning,” in *OCEANS 2016 MTS/IEEE Monterey*, pp. 1–5, IEEE, 2016.
- [12] A. Mahmood, M. Bennamoun, S. An, F. Sohel, F. Boussaid, R. Hovey, G. Kendrick, and R. Fisher, “Coral classification with hybrid feature representations,” in *Image Processing (ICIP), 2016 IEEE International Conference on*, pp. 519–523, IEEE, 2016.
- [13] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818–2826, 2016.
- [14] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.
- [15] G. Huang, Z. Liu, K. Q. Weinberger, and L. van der Maaten, “Densely connected convolutional networks,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, vol. 1, p. 3, 2017.
- [16] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9, 2015.
- [17] A. Shihavuddin, “Coral reef dataset, v2.” Mendeley data <https://data.mendeley.com/datasets/86y667257h/2>, 2017. Accessed on 12-02-2018.
- [18] M. D. Ferreira, D. C. Corrêa, L. G. Nonato, and R. F. de Mello, “Designing architectures of convolutional neural networks to solve practical problems,” *Expert Systems with Applications*, vol. 94, pp. 205–217, 2018.
- [19] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, “Imagenet: A large-scale hierarchical image database,” in *Computer Vision and Pattern Recognition (CVPR), 2009. IEEE Conference on*, pp. 248–255, IEEE, 2009.
- [20] S. Tabik, D. Peralta, A. Herrera-Poyatos, and F. Herrera, “A snapshot of image pre-processing for convolutional neural networks: case study of mnist,” *Int J Comput Intell Syst*, vol. 10, pp. 555–568, 2017.
- [21] M. Bewley, A. Friedman, R. Ferrari, N. Hill, R. Hovey, N. Barrett, E. M. Marzinelli, O. Pizarro, W. Figueira, L. Meyer, *et al.*, “Australian sea-floor survey data, with images and expert annotations,” *Scientific data*, vol. 2, p. 150057, 2015.
- [22] F. Chollet *et al.*, “Keras.” <https://github.com/keras-team/keras>, 2015.
- [23] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Watkinson, M. Wicke, Y. Yu, and X. Zheng, “TensorFlow: Large-scale machine learning on heterogeneous systems,” 2015. Software available from tensorflow.org.
- [24] F. Yu, “Resnet and densenet cnns in keras.” [https://github.com/flyyufelix/cnn\\_finetune](https://github.com/flyyufelix/cnn_finetune), 2017.

---

# **I Workshop en Deep Learning (DeepL)**

SESIÓN 2







# Representaciones basadas en redes neuronales para tareas de recomendación

Pablo Pérez-Núñez  
Centro de Inteligencia Artificial  
Universidad de Oviedo en Gijón  
Gijón, España  
UO232368@uniovi.es

Oscar Luaces  
Centro de Inteligencia Artificial  
Universidad de Oviedo en Gijón  
Gijón, España  
oluaces@uniovi.es

Antonio Bahamonde  
Centro de Inteligencia Artificial  
Universidad de Oviedo en Gijón  
Gijón, España  
abahamonde@uniovi.es

Jorge Díez  
Centro de Inteligencia Artificial  
Universidad de Oviedo en Gijón  
Gijón, España  
jdiez@uniovi.es

**Resumen**—Los sistemas de recomendación tratan de conocer, de alguna manera, los gustos de los usuarios con el propósito de recomendar productos que sean de su agrado. La manera de representar a los usuarios tiene un rol importante en estos sistemas, ya que se espera que una buena representación facilite la correcta identificación del perfil de consumo de cada usuario, sintetizando, de alguna manera, sus gustos. No es menos importante la manera en la que se representan los productos, donde el contexto u orden en que se consumen podría ser relevante en su representación. En este artículo se analizan varias formas de representación basadas en redes neuronales y se aplican a dos tareas de recomendación diferentes en un conjunto de reproducciones musicales. Los resultados muestran que parece relevante considerar el orden de consumo para la codificación de los productos pero no para la codificación del perfil de los usuarios.

**Index Terms**—perfiles de usuario, sistemas de recomendación, factorización, filtros colaborativos

## I. INTRODUCCIÓN

La mayor parte de los recursos digitales que utilizamos hoy en día realizan recomendaciones a sus usuarios utilizando Sistemas de Recomendación ([1], [2]). Así sucede, por ejemplo, cuando entramos en la web de un periódico digital, donde el orden en el que están colocadas las noticias ya es, de alguna manera, una recomendación de lectura. Las listas ordenadas de noticias que aparecen en los márgenes (“*las noticias más leídas*” o “*las más comentadas*”) constituyen también una recomendación, basada en este caso, en la interacción de otros usuarios con la publicación digital. Otro ejemplo de recomendación podemos encontrarlo dentro de los artículos, en forma de enlaces, que nos conducen a otras noticias u otras recomendaciones del tipo “*noticias relacionadas*”.

Los sistemas de recomendación han encontrado en las tiendas online un campo de aplicación muy importante, con el

objetivo de incrementar las ventas al tiempo que aumentar la satisfacción de los clientes. En este caso, lo que se recomienda son productos y las recomendaciones que se realizan son del estilo “*los clientes que vieron este producto también vieron...*”, “*comprados juntos habitualmente*” o incluso rankings de productos en función del número de ventas o de las críticas de los compradores. Podemos también encontrar recomendaciones en las plataformas de streaming de contenido multimedia, por ejemplo, Netflix o Spotify, en sitios web dedicados a organizar las reseñas de hoteles y restaurantes, como TripAdvisor, etc.

Algunos de los ejemplos antes mencionados son sistemas de recomendación elementales, no personalizados, que basan sus recomendaciones simplemente en comportamientos o gustos mayoritarios: si mucha gente ve una película y, además, las valoraciones que tiene ésta son muy buenas, entonces es bastante probable que se recomiende a los usuarios que todavía no la hayan visto.

Sin embargo, hay otros sistemas que basan sus recomendaciones teniendo en cuenta información adicional presente en el contexto. Uno de los más básicos ya se comentó en un párrafo anterior: cuando se detecta que un usuario está viendo información de un producto, el sistema le muestra productos que se parecen o que se compran junto con el que está viendo. Este sistema tiene en cuenta el producto que se está viendo para hacer una recomendación personalizada.

Hay otro tipo de recomendadores que almacenan un perfil para cada usuario en el que, de alguna manera, están contenidos sus gustos o preferencias [3]. Posteriormente, estos perfiles podrán combinarse para hacer recomendaciones personalizadas, con lo que se conseguirá una mayor satisfacción del usuario ante la recomendación. La forma en la que se calcule ese perfil podrá ser más o menos elaborada.

Una manera de tener en cuenta ese perfil de consumo consiste en representar cada usuario con un vector que codifique

El trabajo realizado en este artículo ha sido financiado, en parte, por el proyecto TIN2015-65069-C2-2-R del Ministerio de Economía y Competitividad y por los fondos FEDER.

la información relativa a su interacción<sup>1</sup> con los productos. Esto puede lograrse mediante, por ejemplo, la construcción de *embeddings* utilizando factorización de matrices [4]. De igual forma, los productos también pueden representarse por vectores que resuman la interacción que se ha tenido con ellos. En este artículo vamos a explorar los beneficios que pueden obtenerse al utilizar dos técnicas basadas en redes neuronales, *word2vec* [5] y *doc2vec* [6], para la codificación de usuarios y de productos. Estos algoritmos han sido diseñados originalmente para la codificación de palabras y documentos en procesos que requieren representar textos para tareas de aprendizaje. La codificación que obtienen está basada en el contexto de cada palabra en cada documento. El consumo de cierto tipo de productos también guarda relación con el contexto temporal, por ejemplo, la reproducción de una secuencia de canciones (*playlist*), por lo que podemos utilizar estas técnicas para las tareas de codificación. Con objeto de mostrar la relevancia de este orden secuencial, en este trabajo comparamos la codificación obtenida mediante estas técnicas frente a otra, que se obtiene al construir un *embedding* a partir de una codificación *one-hot*, donde no se tiene en cuenta el orden de consumo en manera alguna.

Una decisión que debe ser adoptada para codificar los perfiles de consumo de los usuarios es cuánto nos vamos a remontar en la secuencia temporal para construir y codificar dicho perfil. En este artículo hemos considerado y comparado la codificación que se obtiene considerando una trayectoria de consumo reciente y una trayectoria de consumo a largo plazo. Es posible que, en determinadas situaciones, sea interesante mantener estos dos perfiles, sobre todo cuando los productos para los que se quiere realizar recomendaciones tengan un comportamiento estacional. Ejemplos de este tipo pueden encontrarse en la alimentación, donde hay algunos platos que se consumen más durante el invierno y otros durante el verano.

Los sistemas de recomendación pueden clasificarse en dos grandes grupos: por una parte podemos construir *filtros colaborativos* [7], en los que se utiliza únicamente la información que se tiene sobre la interacción de los usuarios con los productos y este comportamiento puede darnos una idea de sus gustos o preferencias. Por otra parte, existen también sistemas de recomendación *basados en contenido* [8], donde se utiliza información conocida de los usuarios, como puede ser su ubicación, el sexo, etc. e información conocida de los productos, por ejemplo, género y fecha de estreno si se tratase de películas. En este tipo de sistemas se pueden tener perfiles de clientes y productos basándose en esos datos conocidos.

En este artículo hemos utilizado únicamente filtros colaborativos puesto que queremos estudiar la utilidad de codificar perfiles que resuman la interacción registrada entre usuarios y productos. Incluir información basada en contenido podría distorsionar este estudio, si bien es probable que los resultados

en cuanto a precisión en la recomendación puedan ser mejores, pues tendríamos de más información.

La organización del artículo se muestra a continuación: en la siguiente sección se hace una breve reseña de trabajos previos relacionados con la elaboración de perfiles. La Sección III se dedica a detallar cómo se pueden codificar los perfiles utilizando las técnicas incluidas en *word2vec* y *doc2vec*, que se utilizarán para codificar y comparar dos tipos de perfiles, uno a largo plazo (*perfil consolidado*) y otro a corto plazo (*perfil reciente*) para cada usuario. Seguidamente, en la Sección IV, se detallarán dos tareas de recomendación en las que se va a comprobar el rendimiento de estos perfiles. En la Sección V, dedicada a los resultados, se mostrará el rendimiento de los perfiles en las dos tareas planteadas, discutiendo los resultados obtenidos. Finalmente, se presentan las conclusiones y se apunta alguna línea futura de investigación en este contexto.

## II. TRABAJO RELACIONADO

Son varios los trabajos que abordan la creación de perfiles utilizando la factorización de matrices como herramienta.

En [9] los autores presentan un algoritmo que proyecta cantantes y canciones en un nuevo espacio utilizando factorización de matrices. Las tareas de aprendizaje que se abordan en este trabajo están relacionadas con la predicción de artistas que han podido interpretar una canción, la predicción de canciones que han podido ser interpretadas por un determinado artista, la obtención de canciones similares (en algún sentido) a una dada o la obtención de artistas similares a uno dado. Estas preguntas son, realmente, tareas de recomendación y las proyecciones de cantantes y canciones pueden ser consideradas perfiles.

Algo similar se plantea en [10], donde en este caso se calculan las representaciones de usuarios y canciones con el objetivo de generar *playlists* del agrado de los usuarios.

La factorización de matrices también se ha utilizado para condensar los gustos de las personas respecto a productos alimenticios. En [4] los autores obtuvieron perfiles de consumidores útiles para conocer sus preferencias respecto al consumo de carne con diferentes periodos maduración.

Hasta donde nosotros sabemos, no hay trabajos en los que se plantee una codificación de los productos basándose en el contexto u orden en el que los usuarios interactúan con ellos. Tampoco tenemos constancia de trabajos en los que se discuta la necesidad de mantener dos perfiles para cada usuario, uno representando los gustos consolidados del usuario y otro representando los recientes.

## III. CREACIÓN DE PERFILES A PARTIR DE LA INTERACCIÓN DE LOS USUARIOS CON LOS PRODUCTOS

Supongamos un conjunto de usuarios,  $\mathcal{U}$ , y un conjunto de productos,  $\mathcal{P}$ . Además, conocemos las interacciones que ha tenido cada usuario con los productos y en qué orden se ha producido dicha interacción, de tal manera que para cada usuario disponemos de una lista ordenada de productos con los que ha interactuado a lo largo del tiempo:

$$\mathcal{D} = \{(\mathbf{u}, \mathbf{p}_1, \mathbf{p}_2, \dots) : \mathbf{u} \in \mathcal{U}, \mathbf{p}_i \in \mathcal{P}\} \quad (1)$$

<sup>1</sup>A lo largo de este artículo utilizamos la palabra *interacción* para referirnos a cualquier forma de consumo de un producto: la compra de un ítem, escuchar una canción, ver un producto en una tienda on-line, leer una noticia en una publicación digital, etc.

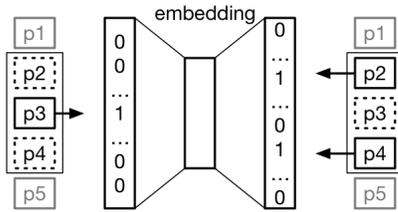


Figura 1. Arquitectura del word2vec utilizando skip-gram con una ventana de tamaño 1 para definir el contexto, que será la suma de los vectores one-hot de las palabras contenidas en el mismo

A partir de esta información aplicaremos los algoritmos word2vec y doc2vec para obtener los perfiles de productos y usuarios.

Los conjuntos  $\mathcal{U}$  y  $\mathcal{P}$  contienen únicamente los identificadores de los usuarios y productos, respectivamente. Una representación habitual para los elementos de estos conjuntos consiste en utilizar vectores *one-hot*, que son vectores cuya dimensión es igual a la cardinalidad del conjunto de elementos que representan. Un vector one-hot que represente al  $i$ -ésimo elemento del conjunto tiene un 1 en la componente  $i$  y todas las demás son 0. Los algoritmos word2vec y doc2vec, que describimos brevemente a continuación, se encargarán de recodificar estos vectores, calculando unos *encajes* (*embeddings*) en los que se tiene en cuenta la secuencia de aparición de los distintos elementos en los datos de entrada.

### III-A. Codificación de los productos

Word2vec [5] es un algoritmo ideado para codificar las palabras de un corpus mediante vectores, de tal manera que éstos se disponen en el espacio de acuerdo a cómo se relacionan en los textos del corpus. Así, aquellas palabras con representaciones próximas suelen tener una relación fuerte.

Los vectores aprendidos para las palabras codifican ciertos patrones lingüísticos, que quedan patentes al realizar operaciones con los vectores resultantes, ya que, como se explica en [5], si al vector que representa la palabra *Madrid* se le resta el que representa la palabra *España* y se le suma el de *Francia*, resultará un vector muy cercano al que representa *París*.

Los autores plantean dos posibles estrategias para la recodificación de palabras, que resultan en dos tareas de aprendizaje:

- *Continuous Bag of Words (CBOW)*, donde a partir de las palabras del contexto se trata de predecir la central, y
- *Skip-gram*, donde a partir de la palabra central se trata de predecir las del contexto (Figura 1).

En ambos casos, el contexto se define mediante un tamaño de ventana y se representa como un vector que es la suma de los vectores one-hot de las palabras contenidas en él. La Figura 1 muestra un esquema de word2vec utilizando skip-gram, en el instante en que se presenta como entrada la palabra  $p_3$  y como salida deseada su contexto que, en este caso, son las palabras  $p_2$  y  $p_4$  o, más específicamente, el vector suma de los vectores que representan a dichas palabras. Entre la entrada y la salida hay una capa oculta, en la que obtendremos la representación buscada tras el proceso de entrenamiento.

Los autores afirman en su artículo que la estrategia skip-gram ofrece mejores resultados y, por tanto, esta estrategia es la que utilizaremos para la obtención de las representaciones de los productos en nuestro sistema de recomendación.

En un símil con el tratamiento de textos, nosotros consideramos la lista de interacciones con productos de la Ecuación (1) como si fuese una secuencia de palabras en un texto de forma que, para un determinado tamaño de ventana trataremos de aprender a predecir con qué productos ha habido interacción antes y después de la interacción con uno determinado.

### III-B. Codificación de los usuarios

Tras aprender la codificación de los productos a partir de cómo los usuarios han interactuado con ellos, podemos obtener el perfil de cada usuario. Para ello proponemos utilizar el algoritmo doc2vec [6], que ha sido diseñado para codificar documentos o párrafos a partir de palabras codificadas mediante word2vec. En su artículo, los autores afirman que las representaciones obtenidas por este algoritmo mejoran el rendimiento en tareas de Recuperación de Información respecto al popular *Bag Of Words*. Para aprender la codificación de documentos, los autores también sugieren dos arquitecturas:

- *Distributed Memory version of Paragraph Vector (PV-DM)*, en la que se aprende a codificar cada documento en un proceso en el que se trata de predecir cuál es la siguiente palabra a una secuencia (ventana) de palabras del documento. La entrada al sistema es la concatenación del vector que representa al documento con los que representan a las palabras de la ventana seleccionada. El aprendizaje únicamente modifica la codificación de cada documento, minimizando el error de predicción, mientras que la codificación de las palabras (obtenida previamente mediante word2vec) se mantiene fija.
- *Distributed Bag of Words version of Paragraph Vector (PV-DBOW)*, donde se toma un documento y se eligen al azar unas cuantas palabras del mismo. A partir únicamente del vector que representa el documento se aprende su codificación para predecir la presencia, sin importar el orden, de las palabras anteriormente elegidas.

El objetivo final en ambos casos es ir modificando durante el entrenamiento la representación de cada documento. En [6], los autores muestran el buen rendimiento de estas representaciones, proponiendo el cálculo de ambas, PV-DM y PV-DBOW, para su utilización de manera concatenada.

En nuestro trabajo consideraremos la lista de productos con los que un usuario ha interactuado, Ecuación (1), como el equivalente a un documento, de manera que habrá un documento por cada usuario. Podremos entonces utilizar doc2vec para la obtención de un vector que codifique a cada usuario. En otras palabras, identificaremos el perfil de un usuario por la secuencia de productos con los que tuvo interacción.

### III-C. Perfil consolidado y perfil reciente

Una vez que se han presentado las herramientas con las que trabajaremos, vamos a definir cómo se pueden obtener el perfil consolidado y el perfil reciente de los usuarios.

Esencialmente, el procedimiento es el mismo para ambos perfiles, pero la diferencia radica en los datos con que entrenaremos la red doc2vec. Así, para obtener un perfil consolidado utilizaremos toda la información disponible acerca de las interacciones del usuario con los productos, independientemente del momento en que se haya producido cada interacción. Nuestra intención es que el perfil consolidado registre o codifique todos los intereses del usuario a lo largo del tiempo.

Sin embargo, para efectuar cierto tipo de recomendaciones puede ser de poca utilidad la información relativa al consumo mucho tiempo atrás. Esto sucede, por ejemplo, en la recomendación de listas de reproducción de canciones, en las que, para añadir un nuevo tema del agrado del usuario parece obvio que es más importante tener en consideración las canciones que acaba de escuchar, que aquellas que escuchó hace semanas, o meses. Por esta razón hemos considerado la codificación de perfiles recientes, que se obtendrán entrenando doc2vec únicamente con las interacciones más recientes del usuario. Obviamente, el umbral de decisión que determina qué interacciones son recientes y cuáles no lo son dependerá del tipo de productos que se vayan a recomendar.

#### IV. TAREAS DE RECOMENDACIÓN

Vamos a estudiar el rendimiento de los mecanismos de representación de productos y usuarios antes mencionados en dos problemas que se detallan a continuación. Los resultados (Sección V) se compararán con los obtenidos utilizando la codificación basada en vectores one-hot.

##### IV-A. Tarea 1: ¿interactuará con un determinado producto?

Para resolver esta tarea contamos con un conjunto de entrenamiento cuyos ejemplos son tripletas que contienen un usuario, un producto y si dicho usuario ha interactuado o no con dicho producto, esto es,

$$\mathcal{D}_1 = \{(\mathbf{u}, \mathbf{p}, z) : \mathbf{u} \in \mathcal{U}, \mathbf{p} \in \mathcal{P}, z \in \{+1, -1\}\}. \quad (2)$$

El algoritmo que diseñamos para resolver esta tarea aprenderá utilizando la siguiente función logística:

$$\Pr(z|\mathbf{u}, \mathbf{p}, \mathbf{W}, \mathbf{V}) = \sigma(z \cdot g(\mathbf{u}, \mathbf{p}, \mathbf{W}, \mathbf{V})), \quad (3)$$

$$\text{con } \sigma(x) = \frac{1}{1 + e^{-x}},$$

donde  $\mathbf{W}$  y  $\mathbf{V}$  son parámetros que deben ser encontrados utilizando la estimación *Máxima Probabilidad a Posteriori (MAP)*, y  $g$  es una función de compatibilidad entre los usuarios y los productos, definida como el producto escalar:

$$g(\mathbf{u}, \mathbf{p}, \mathbf{W}, \mathbf{V}) = \langle \mathbf{W}\mathbf{u}, \mathbf{V}\mathbf{p} \rangle. \quad (4)$$

Para enriquecer la expresividad del modelo aprendido se incorporarán términos independientes.

La función de pérdida a minimizar es, en este caso,

$$-\log \prod_{(\mathbf{u}, \mathbf{p}, z)} \Pr(z|\mathbf{u}, \mathbf{p}, \mathbf{W}, \mathbf{V}) = \log \left( 1 + e^{-z \langle \mathbf{W}\mathbf{u}, \mathbf{V}\mathbf{p} \rangle} \right), \quad (5)$$

también conocida como *softplus*.

##### IV-B. Tarea 2: ¿cuál será el siguiente producto?

La segunda de las tareas a resolver es tratar de anticiparnos a la interacción inmediatamente siguiente del usuario. En este caso el conjunto de entrenamiento estará formado por tripletas conteniendo el usuario,  $\mathbf{u}$ , el último producto con el que ha interactuado,  $\mathbf{p}_i$  y el siguiente producto con el que interactuó a continuación,  $\mathbf{p}_j$ ,

$$\mathcal{D}_2 = \{(\mathbf{u}, \mathbf{p}_i, \mathbf{p}_j) : \mathbf{u} \in \mathcal{U}, \mathbf{p}_i, \mathbf{p}_j \in \mathcal{P}\}. \quad (6)$$

En este caso el algoritmo podría diseñarse aprendiendo la siguiente función:

$$\Pr(y = j|\mathbf{u}, \mathbf{p}_i, \theta) = \frac{e^{v_j}}{\sum_k e^{v_k}} = \text{softmax}(v)_j \quad (7)$$

siendo  $j$  el identificador del producto  $\mathbf{p}_j$ ,  $k$  el de cualquier producto,  $\theta$  el conjunto de parámetros (pesos de una red neuronal, por ejemplo) que se deben aprender y  $v$  el valor de salida de la red cuya entrada es la concatenación del usuario y el producto. También incorporamos un término independiente.

La función de pérdida habitual en problemas de este tipo es la *entropía cruzada (cross entropy)*. Sin embargo, cuando el número de clases es elevado, algo común en los problemas de recomendación, el cálculo de  $\text{softmax}(v)$  es muy costoso, por lo que se recurre a estrategias de estimación del error, como la denominada *noise-contrastive estimation (NCE)* [11], que hemos utilizado en este trabajo.

#### V. RESULTADOS EXPERIMENTALES

En esta sección describimos y analizamos los resultados experimentales que hemos obtenido utilizando distintas codificaciones para usuarios y productos. Más concretamente, hemos analizando el rendimiento de tres perfiles diferentes para los usuarios y dos para los productos.

##### V-A. Descripción del conjunto de datos

Para la experimentación hemos utilizado un conjunto de datos de la web *www.last.fm*, que han sido previamente publicados en el capítulo 3 del libro [12] y que se encuentran disponibles públicamente<sup>2</sup>. El conjunto contiene las reproducciones de música de 992 usuarios durante 5 años, aproximadamente. En total hay algo más de 19 millones de reproducciones sobre un conjunto de un millón y medio de canciones. En el conjunto también aparece la fecha y hora exactas de cada reproducción, con lo que no es complicado elaborar para cada usuario una lista ordenada como la que se muestra en la Ecuación (1).

##### V-B. Preparación de los experimentos

Hemos filtrado el conjunto, eliminando canciones repetidas o que se habían escuchado muy poco, quedándonos sólo con aquellas que se han escuchado al menos 10 veces, con lo que hemos reducido el conjunto a 312895 canciones.

Cada lista de reproducción asociada a un usuario fue separada en una parte para entrenar los perfiles (75%) y otra para utilizar en las tareas propuestas (25%), ver Figura 2.

<sup>2</sup><http://www.dtic.upf.edu/~ocelma/MusicRecommendationDataset/lastfm-1K.html>

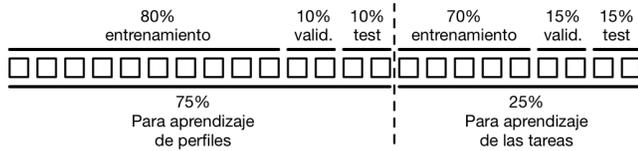


Figura 2. Método que se utiliza para la separación de la lista de reproducción de cada usuario en conjuntos de entrenamiento, validación y test

A su vez, cada una de estas dos partes fue separada en entrenamiento/validación/test, utilizando las partes de entrenamiento y validación para buscar los hiper-parámetros con mejor rendimiento. Los resultados que se muestran en las tablas son los obtenidos con estos modelos al evaluar su rendimiento sobre el conjunto de test.

Todos los algoritmos utilizados en este artículo fueron implementados utilizando la librería TensorFlow [13] sobre Python, y el optimizador SGD-Adam [14].

### V-C. Obtención de perfiles

Para codificar las canciones utilizamos word2vec sobre el conjunto de datos correspondiente, usando un tamaño de ventana de 2 y con objeto de obtener vectores en un espacio de 64 dimensiones. Estos parámetros eran los que mejores resultados mostraban sobre el conjunto de validación.

Una vez codificadas las canciones, se codificaron los usuarios mediante la red doc2vec de dos maneras diferentes, una para obtener el perfil consolidado ( $P_{con}$ ) y otra para el perfil reciente ( $P_{rec}$ ). En ambos casos también utilizamos un espacio de 64 dimensiones, con una ventana de tamaño 2 (para la arquitectura PV-DM) y seleccionando todas las reproducciones del entrenamiento (para la arquitectura PV-DBOW). Al calcularse mediante los dos métodos propuestos en la Sección III-B y concatenarlos, finalmente los usuarios quedan proyectados en un espacio de 128 dimensiones. Para el cálculo del  $P_{con}$  se utilizaron todas las reproducciones reservadas para el aprendizaje de los perfiles, mientras que para el  $P_{rec}$  se utilizaron solo las reproducciones del último mes para cada usuario.

Finalmente, obtuvimos una codificación en la que los vectores de los usuarios y productos, en formato one-hot, son proyectados en un espacio de 64 dimensiones para las canciones y de 128 dimensiones para los usuarios. Utilizamos las mismas dimensiones que las de los perfiles obtenidos con word2vec y doc2vec con el fin de que los espacios tengan la misma capacidad expresiva y la comparación sea justa. La proyección se realiza a través de un encaje (embedding) que resulta del proceso de aprendizaje de cada tarea de recomendación, mediante el cálculo de dos matrices,  $X$  e  $Y$ , que proyectan cada usuario y cada canción en un espacio con las dimensiones antes especificadas (ver Figuras 3 y 4).

### V-D. Tarea 1

Para la tarea de aprender un modelo capaz de indicarnos si un usuario va a escuchar una canción en el futuro, resolvemos el problema de optimización planteado en la Sección IV-A.

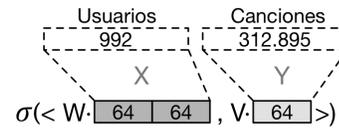


Figura 3. Red diseñada para la tarea 1, Ecuación (3). El vector que define el perfil del usuario (gris oscuro) y el de la canción (gris claro) pueden ser precalculados mediante doc2vec y word2vec, respectivamente o pueden aprenderse ad-hoc para resolver la tarea, a partir de la representación one-hot y optimizando los parámetros ( $X$  e  $Y$ ) necesarios.

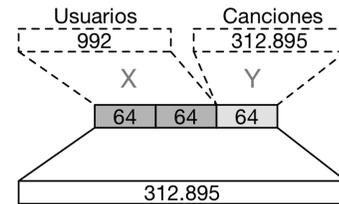


Figura 4. Red diseñada para la tarea 2, Ecuación (7). Las distintas codificaciones para usuarios y canciones son las mismas que para la tarea 1.

El conjunto  $\mathcal{D}_1$  de la Ecuación (2) se construye utilizando la parte de entrenamiento de las reproducciones reservadas para el aprendizaje de las tareas (25%), como se representa en la Figura 2. Las canciones contenidas en ese subconjunto de datos se etiquetan con +1, y, por cada una de ellas, se elegirá al azar una canción que el usuario no haya escuchado previamente, que se etiquetará con -1.

En la Tabla I se recogen los resultados, medidos en *Precision*, *Exhaustividad (Recall)* y *F1* (media armónica de las anteriores). En estos resultados se aprecia que la utilización del perfil de las canciones obtenido mediante word2vec favorece el aprendizaje. En cuanto a los perfiles de usuario, no parece que la incorporación de perfiles obtenidos mediante doc2vec mejoren el rendimiento, si bien parece más útil el perfil consolidado que el perfil reciente para este problema.

### V-E. Tarea 2

Para resolver el problema de optimización de la Sección IV-B (predecir la siguiente canción a reproducir) utilizaremos una red con la estructura de la Figura 4, que entrenaremos con el conjunto  $\mathcal{D}_2$  de la Ecuación (6), en el que los pares consecutivos de canciones reproducidas se construyen utilizando los datos reservados para el aprendizaje de tareas (25%). El resto de datos se utiliza para obtener las codificaciones con word2vec y doc2vec, como en la tarea anterior.

Tabla I  
TABLA DE RESULTADOS PARA LA TAREA 1

Representación		Precision	Recall	F1
Usuario	Canción			
one-hot	one-hot	77.5	73.8	75.6
one-hot	word2vec	<b>83.1</b>	<b>80.2</b>	<b>81.6</b>
$P_{con}$	word2vec	80.5	79.1	79.8
$P_{rec}$	word2vec	77.5	74.5	76.0

Tabla II  
TABLA DE RESULTADOS PARA LA TAREA 2

Representación		Precisión						Mediana
Usuario	Canción	$P@5$	$P@10$	$P@20$	$P@50$	$P@100$	$P@1000$	
one-hot	one-hot	1.4	1.8	2.5	4.1	6.2	18.3	17476
one-hot	word2vec	7.7	<b>12.3</b>	<b>17.4</b>	<b>25.2</b>	<b>31.8</b>	<b>58.6</b>	<b>511</b>
$P_{con}$	word2vec	7.3	9.6	12.8	18.2	23.8	52.1	857
$P_{rec}$	word2vec	<b>8.3</b>	10.9	14.1	19.4	24.7	50.2	986

Para evaluar el rendimiento de las diferentes combinaciones de perfiles, se utilizó la medida *precision at x* ( $P@x$ ), donde  $x$  varía en valores entre 5 y 1000. De esta manera podremos ver el porcentaje de veces que la canción que realmente va a escuchar el usuario se encuentra entre las  $x$  que más probabilidad les otorga el modelo aprendido. Los resultados de la Tabla II muestran que, nuevamente, la utilización de un perfil precalculado con word2vec para las canciones mejora el rendimiento considerablemente.

Para los perfiles de usuario, los mejores resultados se obtienen con la codificación resultante de la representación one-hot, calculada durante el aprendizaje de la tarea. Si enfrentamos el perfil reciente al consolidado, parece que el reciente ofrece mejor rendimiento, lo cual tiene sentido debido a la naturaleza de la tarea. Cabe destacar que los bajos valores de  $P@5$  (por debajo del 10% en todos los casos) se deben a que la tarea de recomendación es muy difícil: con tan sólo 5 recomendaciones se le pide al sistema acertar la siguiente canción entre 312895 alternativas posibles. La última columna de la tabla muestra la mediana de la posición que ocupa la canción que debería predecirse para acertar ( $p_j$  en la Ecuación 6) en el ranking que se obtiene atendiendo a la probabilidad predicha para cada canción. El valor 511 no es un mal resultado, teniendo en cuenta que hay más de trescientas mil canciones posibles.

Doc2vec, en su versión PV-DM, es entrenado para intentar predecir la siguiente canción, como en esta tarea 2. Los resultados que obtiene son ligeramente mejores, pero utiliza las dos últimas canciones escuchadas por el usuario.

## VI. CONCLUSIONES Y TRABAJO FUTURO

Los Sistemas de Recomendación tienen muchas aplicaciones en la actualidad. Su éxito radica, principalmente, en la personalización que se está consiguiendo en las recomendaciones. Es por esto que la creación de perfiles de productos y usuarios cobra especial importancia.

En este artículo hemos evaluado el rendimiento de perfiles precalculados mediante el uso de las redes neuronales word2vec y doc2vec, y los hemos comparado con la codificación que se obtiene al calcular un embedding de los vectores de entrada a un espacio de forma que se optimiza un determinado objetivo. La comparación se ha efectuado en el contexto de dos tareas de aprendizaje: una de carácter más inmediato, predecir la siguiente canción a escuchar, y otra a más largo plazo, predecir si una canción se va a escuchar en el futuro.

Los resultados muestran que el rendimiento de los sistemas de recomendación mejora sustancialmente al introducir el perfil precalculado para las canciones mediante word2vec. Sin

embargo, el perfil obtenido para los usuarios con doc2vec no mejora el rendimiento que se obtiene con la codificación obtenida a partir de vectores one-hot.

Como trabajo futuro, sería interesante obtener perfiles de usuario utilizando una red LSTM [15], ya que este tipo de redes es capaz de olvidar productos vistos hace tiempo.

## AGRADECIMIENTOS

Agradecemos a NVIDIA Corporation la donación de la GPU Titan Xp utilizada en esta investigación.

## REFERENCIAS

- [1] P. Resnick and H. R. Varian, "Recommender systems," *Commun. ACM*, vol. 40, pp. 56–58, Mar. 1997.
- [2] F. Ricci, L. Rokach, and B. Shapira, "Introduction to recommender systems handbook," in *Recommender systems handbook*, pp. 1–35, Springer, 2011.
- [3] J. Díez, D. Martínez-Rego, A. Alonso-Betanzos, O. Luaces, and A. Bahamonde, "Metrical representation of readers and articles in a digital newspaper," in *10th ACM Conference on Recommender Systems (RecSys 2016) Workshop on Profiling User Preferences for Dynamic Online and Real-Time Recommendations (RecProfile 2016)*, ACM, 2016.
- [4] O. Luaces, J. Díez, T. Joachims, and A. Bahamonde, "Mapping preferences into euclidean space," *Expert Systems with Applications*, vol. 42, no. 22, pp. 8588 – 8596, 2015.
- [5] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient estimation of word representations in vector space," *CoRR*, vol. abs/1301.3781, 2013.
- [6] Q. V. Le and T. Mikolov, "Distributed representations of sentences and documents," *CoRR*, vol. abs/1405.4053, 2014.
- [7] J. L. Herlocker, J. A. Konstan, and J. Riedl, "Explaining collaborative filtering recommendations," in *Proceedings of ACM Conference on Computer Supported Cooperative Work*, pp. 241–250, ACM, 2000.
- [8] M. J. Pazzani and D. Billsus, "The adaptive web," ch. Content-based Recommendation Systems, pp. 325–341, Berlin: Springer-Verlag, 2007.
- [9] J. Weston, S. Bengio, and P. Hamel, "Multi-tasking with joint semantic spaces for large-scale music annotation and retrieval," *Journal of New Music Research*, vol. 40, no. 4, pp. 337–348, 2011.
- [10] S. Chen, J. L. Moore, D. Turnbull, and T. Joachims, "Playlist prediction via metric embedding," in *Proceedings of the International Conference on Knowledge Discovery and Data Mining*, pp. 714–722, ACM, 2012.
- [11] M. Gutmann and A. Hyvärinen, "Noise-contrastive estimation of unnormalized statistical models, with applications to natural image statistics," *JMLR*, vol. 13, pp. 307–361, 2012.
- [12] O. Celma, *Music Recommendation and Discovery in the Long Tail*. Springer, 2010.
- [13] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mane, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viegas, O. Vinyals, P. Warden, M. Wattemberg, M. Wicke, Y. Yu, and X. Zheng, "TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems," mar 2016.
- [14] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," in *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, 2014.
- [15] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, pp. 1735–1780, Nov 1997.



# Una red convolucional para la clasificación de las fases de sueño

1<sup>st</sup> Isaac Fernández-Varela  
 CITIC  
 Universidade da Coruña  
 A Coruña, España  
 isaac.fvarela@udc.es

2<sup>nd</sup> Elena Hernández-Pereira  
 CITIC  
 Universidade da Coruña  
 A Coruña, España  
 elena.hernandez@udc.es

3<sup>rd</sup> Diego Alvarez-Estevez  
 Sleep Center & Clinical Neurophysiology  
 Haaglanden Medisch Centrum  
 The Hague, The Netherlands  
 diego.alvarez@udc.es

4<sup>th</sup> Vicente Moret-Bonillo  
 CITIC  
 Universidade da Coruña  
 A Coruña, España  
 vicente.moret@udc.es

**Resumen**—La clasificación de fases de sueño es una tarea crucial en el contexto de los estudios de sueño que incluye el análisis de varias señales simultáneamente y, por tanto, es tediosa y compleja. Incluso para un experto entrenado puede costar varias horas anotar las señales registradas durante el sueño de una única noche. Para resolver este problema se han desarrollado métodos automáticos, la mayor parte basándose en características inherentes al conjunto de datos utilizado. En este trabajo evitamos esa imparcialidad resolviendo el problema con un modelo de *deep learning* que puede aprender las características relevantes de las señales del paciente sin nuestra intervención. En concreto, proponemos un *ensemble* de 5 redes convolucionales que obtiene un índice kappa de 0,83 clasificando 500 registros polisomnográficos.

**Palabras clave**—red convolucional, fases de sueño, clasificación

## I. INTRODUCCIÓN

Los trastornos del sueño afectan a una parte mayoritaria de la población. Como ejemplo, el 20% de los adultos españoles sufren insomnio, y entre el 12% y el 15% somnolencia diurna [1, 2]. Dormir bien es esencial para tener buena salud y las consecuencias de la falta de sueño son bien conocidas [3]. Para el diagnóstico de los trastornos del sueño es útil la identificación de las diferentes fases que atraviesa el sueño del paciente. Con este objetivo, la técnica más utilizada es el polisomnograma (PSG) que registra las señales biomédicas del paciente, entre las que se encuentran señales neumológicas, electrofisiológicas e información contextual. Este análisis es caro, incómodo para el paciente y de difícil interpretación. Una manera habitual de simplificar esta interpretación es con el uso del hipnograma, la representación ordenada de la evolución de las fases de sueño.

El estándar de oro para la construcción del hipnograma es la guía de la *American Academy of Sleep Medicine* (AASM) [4] para la identificación de fases del sueño y sus eventos asociados, los despertares, los movimientos y los

eventos cardíacos y respiratorios. Dicha guía identifica cinco fases de sueño: Despierto (*Awake*, W), movimientos oculares rápidos (*Rapid Eye Movements*, REM), y tres fases de sueño lento o no REM (N1, N2 y N3). Un hipnograma construido correctamente facilita encontrar problemas y diagnosticar trastornos del sueño, permitiendo enfocar el tiempo en la terapia. Su construcción implica analizar una gran cantidad de información y conocimiento [5]. Además, pese a las guías el acuerdo entre expertos es usualmente inferior al 90%. Por ejemplo, Stepnowsky et al. [6] estudiaron el acuerdo entre dos expertos obteniendo índices kappa entre 0,48 y 0,89. De manera similar, Wang et al. [7] obtuvieron índices entre 0,72 y 0,85. A mayores, el acuerdo también es menor para fases concretas, siendo la fase N1 la que obtiene los peores resultados.

Por todo ello, la automatización de la clasificación de fases de sueño es una tarea necesaria. La mayor parte de los métodos a día de hoy siguen una aproximación de dos pasos. Primero, extraen características específicas para este problema, muchas veces dependientes de los datos utilizados. Después, construyen un vector de características con el que se entrena algún clasificador y predicen las fases de sueño. Algunos autores utilizan un único canal de una señal y otros utilizan múltiples canales, construyendo un vector de varios elementos. Las características extraídas pueden pertenecer tanto al dominio del tiempo como al de la frecuencia. Aunque algunos trabajos utilizan una única señal, en este caso siempre el electroencefalograma (EEG), otros utilizan varias, incluyendo electrooculograma (EOG) o electromiograma (EMG), para adaptarse a las guías de la AASM.

Entre los métodos que utilizan extracción de características para su posterior clasificación encontramos los siguientes: Fraiwan et al. [8], utilizan un *random forest* para la clasificación de características del dominio del tiempo-frecuencia y las características de entropía de Reny; Liang et al. [9], obtienen la entropía en múltiples escalas y características autoregresivas analizándolas con un discriminante lineal; Has-

\* Esta investigación ha sido financiada en parte por la Xunta de Galicia (ED431G/01) y la Unión Europea a través del fondo ERDF.

san and Bhuiyan [10], utilizan una única señal con transformaciones *wavelet* para la extracción de características y un *random forest* para la clasificación. Sharma et al. [11], también comparan varios clasificadores, utilizando filtros iterativos para analizar un único canal de EEG; Koley and Dey [12], entrenan una *support vector machine (SVM)* con características de frecuencia, de tiempo y no lineales extraídas de un único canal de EEG; Lajnef et al. [13], utilizan varias señales y múltiples SVM para crear un árbol de decisión; Huang et al. [14], estudian la densidad espectral de potencia de 2 canales de EEG para clasificar las características de frecuencia utilizando una modificación de una SVM; Finalmente, Günes et al. [15], también analizan la densidad espectral de potencia pero clasificando con un algoritmo de *nearest neighbors*.

Solucionar el problema de clasificación de fases de sueño con extracción de características provoca sesgos por el diseño de características basadas en un único conjunto de datos. Por ello, las propuestas anteriores no generalizaban bien, concretamente dada la naturaleza de los registros de PSG, que presentan variaciones debido al paciente junto con las que provoca el hardware o el método de adquisición utilizado.

Una alternativa para resolver este problema es utilizar métodos que puedan aprender de los datos, evitando el sesgo humano. En este sentido, la apuesta natural es el *deep learning* ya que ha demostrado mejoras frente a métodos tradicionales en múltiples campos en general y en el diagnóstico médico en particular [16, 17].

Ya existen trabajos que exploran distintos modelos de *deep learning*: Långkvist et al. [18], utilizan redes *deep belief* para aprender una representación probabilística de señales pre-procesadas de PSG; Tsinalis et al. [19], extraen características de una señal EEG y después utilizan redes convolucionales para la clasificación. Los mismos autores en otro trabajo [20] utilizan una pila de *sparse autoencoders*; Supratak et al. [21], utilizan una red convolucional con una red recurrente bidireccional para clasificar directamente a partir de las señales; Biswal et al. [22], comparan una red recurrente contra otros modelos, pero entrenados con características en vez de con la propia señal; Finalmente, Sors et al. [23] también utilizan una red convolucional sobre un único canal de EEG.

En este trabajo se utiliza *deep learning* para clasificar las fases de sueño a través de una red convolucional que puede aprender las características relevantes de cada fase. Siguiendo las guías de la AASM utilizamos múltiples señales; en particular, dos canales de EEG, un canal de EMG y ambos canales de EOG (derecho e izquierdo). Además, las señales se filtran previamente, para reducir el ruido y eliminar artefactos.

## II. MATERIALES

El desarrollo y análisis del modelo que se presenta se realiza utilizando registros reales de pacientes. Dichos registros pertenecen al *Sleep Heart Health Study (SHHS)* [24], una base de datos que ofrece la *Case Western University* que proviene de un estudio entre varios centros dirigido por el *National Heart Lung and Blood Institute* para determinar

las consecuencias cardiovasculares de los trastornos de sueño asociados a la respiración.

Cada registro incluye las anotaciones de distintos eventos, realizadas por expertos siguiendo las reglas de la AASM [25]. Todos los registros se anonimizaron y anotaron a ciegas. El montaje utilizado para la adquisición de las señales incluye entre otras señales dos derivaciones de EEG (C4A2 y C4A1), EOG derecho e izquierdo, un EMG submental, electrocardiograma (ECG). El EEG, EOG y EMG están muestreados a 125 Hz mientras que los EOG están a 50 Hz. Las señales se filtraron durante su adquisición con un filtro paso alto a 0,15 Hz.

Usamos tres conjuntos de datos distintos para entrenar, validar y testear nuestro modelo. El conjunto de entrenamiento incluye 400 registros, el de validación 100 y el de test 500. La duración de los registros de entrenamiento se iguala (se incluyen 7 horas aleatorias por registro) para facilitar la codificación del algoritmo de entrenamiento del modelo. De esta manera, tenemos 288,000 ejemplos para entrenar, 119,121 para la validación y 606,981 para el test. Los registros se escogieron de manera aleatoria incluyendo aquellos con mucho ruido o muchos artefactos.

Las distribuciones de las diferentes clases, tanto para el conjunto de datos entero como para cada registro individual se muestran en la Tabla I. Esta tabla demuestra el desbalanceo de los conjuntos de datos, siendo la fase W predominante (aproximadamente el 38% de los casos), aunque la proporción es similar para la fase N2 (aproximadamente el 36%). Por el contrario, la clase N1 solo está representada en un 3%. También es interesante destacar que algunos registros no tienen ninguno de los casos para alguna clase y lo mucho que varían las proporciones entre ellos. Por ejemplo, en el conjunto de test, mientras un registro contiene un 7,10% para la clase N2, otro contiene un 83,43%. De hecho, estos son los dos principales problemas cuando se clasifican fases de sueño: 1) el gran desbalanceo de las clases y 2) las diferencias entre registros individuales.

## III. MÉTODO

### A. Filtrado de las señales

Las señales son procesadas para eliminar ruido y artefactos comunes. Ambas operaciones son pasos habituales en trabajos previos utilizados antes de la extracción de características.

El primero de los dos filtros utilizados para eliminar ruido es un filtro *Notch* centrado en 60 Hz para eliminar la interferencia que causa la línea de corriente. Este filtro se aplica a las señales con un muestreo superior a 60 Hz, EEG y EMG. El segundo elimina las frecuencias no relacionadas con movimientos musculares del EMG, utilizando un filtro paso alto a 15 Hz.

En cuanto a los artefactos, la mayor parte ocurren durante períodos muy concretos y cortos de tiempo, haciendo que sea incluso difícil reconocerlos. De cualquier manera, los artefactos ECG, causados por las interferencias del latido del corazón, son comunes y constantes a lo largo de toda la señal. Eliminamos estos artefactos usando un filtro adaptativo. Para ello, primero obtenemos la serie de latidos utilizando un



Tabla I  
DISTRIBUCIÓN DE LAS DISTINTAS CLASES EN LOS CONJUNTOS DE ENTRENAMIENTO, VALIDACIÓN Y TEST.

		W	N1	N2	N3	REM	Total
Conjunto de entrenamiento	Total	187.513	17.283	172.451	44.454	62.168	483.869
	Proporción	38,75 %	3,57 %	35,64 %	9,19 %	12,85 %	100 %
	Min en un registro	8,20 %	0,00 %	12,59 %	0,00 %	0,00 %	
	Max en un registro	71,61 %	13,75 %	68,65 %	33,43 %	26,58 %	
Conjunto de validación	Total	43.742	3.963	43.510	12.900	15.006	119.121
	Proporción	36,72 %	3,33 %	36,53 %	10,83 %	12,60 %	100 %
	Min en un registro	11,21 %	0,29 %	12,38 %	0,00 %	0,00 %	
	Max en un registro	76,79 %	17,08 %	60,09 %	30,16 %	23,68 %	
Conjunto de test	Total	231.707	19.769	217.246	61.281	76.978	606.981
	Proporción	37,77 %	3,26 %	35,96 %	10,25 %	12,75 %	100 %
	Min en un registro	7,75 %	0,00 %	7,10 %	0,00 %	0,00 %	
	Max en un registro	76,53 %	16,93 %	83,43 %	43,82 %	31,11 %	

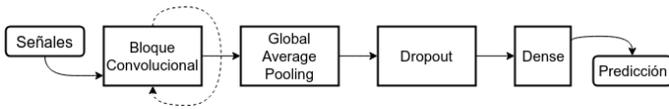


Figura 1. Red convolucional propuesta.

algoritmo estándar de detección de ondas QRS [26]. Después estudiamos la calidad de la señal de ECG para saber que intervalos podemos incluir en la construcción del filtro adaptativo. Por último, durante los intervalos con suficiente calidad, aplicamos y actualizamos el filtro adaptativo para eliminar los artefactos. Este proceso se describe en profundidad en Fernández-Varela et al. [27].

### B. Red convolucional

La clasificación de las fases de sueño se realiza habitualmente con ventanas de 30 s, llamadas epochs. Analizando múltiples características de cada epoch, los expertos clínicos pueden decidir cual es la fase de sueño correspondiente a dicho epoch.

Una red convolucional [28] es una red *deep-forward* que soluciona las limitaciones del perceptrón multicapa con una arquitectura que comparte pesos. Básicamente, aplica una operación de convolución sobre la entrada, reduciendo el número de parámetros. Por eso, permite construir redes más profundas que facilitan reconocer características más complejas. La red propuesta se representa en la Figura 1.

La red convolucional recibe como entrada el conjunto de señales (2 canales de EEG, EMG y ambos EOG). Cada entrada es un epoch: ventana de 30 segundos. Debido a la diferencia de muestreo entre las señales, tal y como se comentó en la Sección II, se realiza una operación de *upsampling* a 125 Hz. Se descarta un *downsample* a 50 Hz porque perderíamos las frecuencias altas del EEG que clínicamente contienen información interesante para clasificar las fases de sueño. De la misma forma, se descarta una operación de *padding* porque no sería fácilmente extensible a otros conjuntos de datos con señales adquiridas con otras frecuencias de muestreo. De esta manera, cada entrada de la red convolucional es una matriz de

$3750 \times 5$ . Cada señal se normaliza con media 0 y desviación 1, obteniendo la media y desviación a partir de todas las señales correspondientes del conjunto de datos de entrenamiento. Usando otras normalizaciones de menor granularidad las redes probadas inicialmente no convergían. El bloque convolucional que se muestra en la Figura 1 es una sucesión de cuatro capas incluyendo una convolución 1D que preserva el tamaño de la entrada (con *padding*), una capa de *batch normalization* [29] para la regularización, una activación ReLu [30] y un *average pool* que reduce el tamaño de la entrada por un factor de 2. Usando una convolución 1D evitamos imponer una estructura espacial que desconocemos entre las distintas señales. Este bloque se repitió  $n$  veces, siendo  $n$  un hiperparámetro cuyo valor fue seleccionado durante la experimentación. Todas las capas se configuraron con el mismo tamaño de kernel pero el número de filtros para la capa  $i$  es dos veces el número de filtros de la capa  $i - 1$ . La selección de  $n$ , el tamaño de kernel y el número inicial de filtros se explica en la siguiente sección, junto a otros hiperparámetros.

La salida del último bloque convolucional, tras ajustar la dimensión con un *global pooling* y aplicarle *dropout* para mejorar la regularización, se utiliza como entrada en una capa densa con activación *softmax*. Esta capa devuelve la probabilidad de cada clase para la entrada. Como es habitual, se selecciona la clase con mayor probabilidad como decisión de clasificación.

Para entrenar la red se utiliza el optimizador Adam [31] con 64 elementos por *batch*. Este tamaño de *batch* está condicionado por el hardware disponible para la ejecución. Del optimizador se configura el hiperparámetro ratio de aprendizaje, manteniendo ambas betas con los valores por defecto. El entrenamiento se termina utilizando *early stopping* monitorizando la pérdida en el conjunto de validación con una paciencia de 10 epochs. Debido al desbalanceo de las clases se utiliza *cross entropy* ponderada, obteniendo los pesos del conjunto de entrenamiento.

### C. Optimización de hiperparámetros

Una correcta elección de los hiperparámetros puede significar el éxito de un modelo *deep learning*. La dificultad a

la hora de seleccionar los mejores hiperparámetros no es sólo obtener el mejor rendimiento sino en conseguirlo minimizando el coste al hacerlo, pudiendo ser este coste económico o computacional.

En este trabajo se utiliza un *Tree-structured Parzen Estimator* (TPE) que se ha mostrado superior frente a otros métodos [32, 33]. El TPE es una aproximación secuencial de optimización basada en modelos (SMBO). Los métodos SMBO construyen secuencialmente modelos para aproximar el rendimiento de una selección de hiperparámetros basándose en resultados históricos y así escoger nuevos hiperparámetros que se comprueban con el modelo. Particularmente, TPE modela dos distribuciones  $P(x|y)$  y  $P(y)$  donde  $x$  representa los hiperparámetros e  $y$  el rendimiento asociado, y optimiza la mejora esperada (*expected improvement*, EI) siguiendo la ecuación:

$$EI_{y^*}(x) = \int_{-\infty}^{y^*} (y^* - y) \frac{P(x|y)P(y)}{P(x)}$$

donde  $y^*$  es algún cuantil  $\gamma$  de los valores observados  $y$  tal que  $p(y < y^*) = \gamma$ .

Utilizamos TPE para optimizar los siguientes hiperparámetros relacionados con la red convolucional: el número de bloques convolucionales, el tamaño del kernel de cada convolución 1D y el número de filtros del primer bloque. A mayores, existe una relación entre el número inicial de filtros y el número de bloques convolucionales. Dadas nuestras restricciones computacionales no añadimos bloques que tuviesen más de 1024 filtros. También se utiliza TPE para el ratio de aprendizaje del optimizador. Las distribuciones usadas para cada uno de estos hiperparámetros se resumen en la Tabla II.

Tabla II  
DISTRIBUCIONES PARA LOS DISTINTOS HIPERPARÁMETROS

Hiperparámetro	Distribución
Bloques convolucionales	Uniforme entre 1 y 10
Tamaño del kernel	Uniforme entre 3 y 50
Filtros iniciales	Elección entre 8, 16, 32 o 64
Ratio de aprendizaje	Log-uniforme entre -10 y -1

Para reducir el tiempo computacional de selección de los hiperparámetros utilizamos un subconjunto del conjunto de entrenamiento para entrenar, validar y hacer el test de los distintos modelos. Este subconjunto contiene 250 registros de los que 20 se utilizan para validación durante el entrenamiento y 50 para el test de cada modelo. En total probamos 50 modelos utilizando el índice kappa para seleccionar el mejor.

#### D. Medidas de rendimiento

El rendimiento de los modelos se evalúa con las siguientes medidas:

- **Precisión**, la fracción entre el número de verdaderos positivos y el número de predicciones positivas.
- **Sensitividad**, la fracción entre el número de verdaderos positivos y el número elementos de la clase.

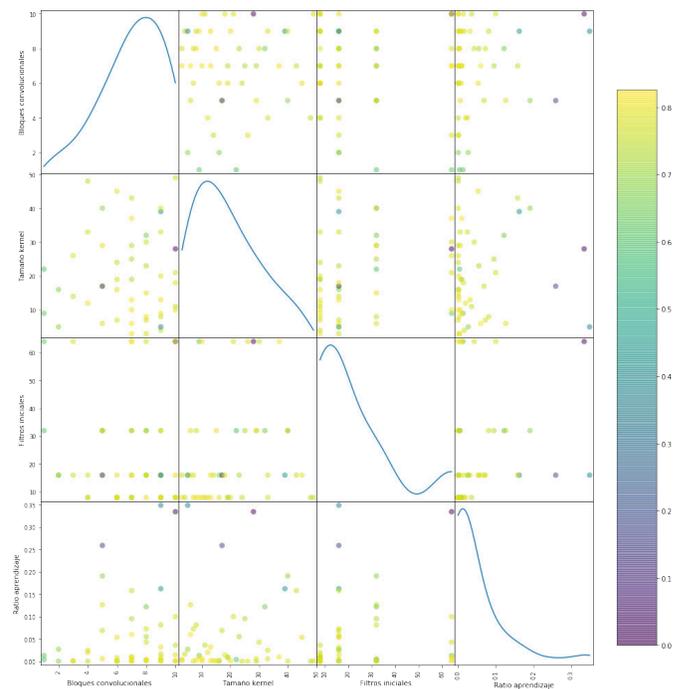


Figura 2. Gráfico de dispersión para los diferentes conjuntos de hiperparámetros probados. El color del punto representa el índice kappa para el modelo con dichos hiperparámetros. La diagonal representa la distribución de los valores asignados para ese hiperparámetro concreto.

- **F1 score**, la media armónica de precisión y sensitividad.
- **Kappa**, la medida del acuerdo entre dos clasificadores que tiene en cuenta la posibilidad de acuerdo casual. El acuerdo perfecto obtiene un valor de 1 y solo por casualidad un valor 0.

## IV. RESULTADOS

Antes de ver los resultados conseguidos podemos visualizar el rendimiento que obtuvieron los distintos modelos probados para la búsqueda de hiperparámetros en la Figura 2. Destaca la necesidad de un ratio de aprendizaje bajo para que el entrenamiento converja adecuadamente.

Para mejorar los resultados obtenidos por nuestro modelo utilizamos un *ensemble*. Varios modelos clasifican las fases de sueño de manera individual y el resultado final es la fase más repetida. En este caso, hemos escogido los 5 mejores modelos obtenidos durante la selección de hiperparámetros. Los valores para los hiperparámetros de cada uno de ellos se presentan en la Tabla II.

Los resultados obtenidos por el *ensemble* utilizando el conjunto de test se muestran en la Tabla IV. La mejor clasificación se obtiene para la clase W, con valores cercanos a 0,95 para la precisión, sensitividad y *F1 score*; después las clases N2, N3 y REM presentan resultados similares, especialmente si nos fijamos en la *F1 score*, aunque con menor sensitividad para la clase N3 y, por tanto, también mayor precisión. Por último, los resultados no son los esperados para la clasificación de la fase N1, no llegándose a un *F1 score* de 0,3. Típicamente, N1 es la clase más difícil de clasificar incluso para los expertos.



Tabla III  
HIPERPARÁMETROS PARA LOS 5 MEJORES MODELOS

Parámetro	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Bloque convolucionales	7	9	7	7	7
Tamaño del kernel	6	9	13	3	10
Filtros iniciales	16	8	8	8	64
Ratio de aprendizaje	$5,99 \times 10^{-2}$	$9,00 \times 10^{-3}$	$1,45 \times 10^{-3}$	$1,91 \times 10^{-3}$	$5,49 \times 10^{-3}$

Tabla IV  
MEDIDAS DE RENDIMIENTO PARA LA CLASIFICACIÓN DEL CONJUNTO DE TEST UTILIZANDO EL ENSEMBLE DE LOS 5 MEJORES MODELOS.

Fase	Precisión	Sensitividad	<i>F1 score</i>
W	0,94	0,96	0,95
N1	0,39	0,21	0,27
N2	0,87	0,89	0,88
N3	0,92	0,77	0,84
REM	0,82	0,90	0,86
<b>Average</b>	0,78	0,75	0,76

La matriz de confusión obtenida con el *ensemble* se muestra en la Figura 3, en la que se puede comprobar que la mayor parte de las fases N1 son clasificadas como otras fases, especialmente N2. Además, aunque en una proporción mucho menor, cuando se comete un error clasificando una clase distinta a N2, también se tiende a clasificar como N2.

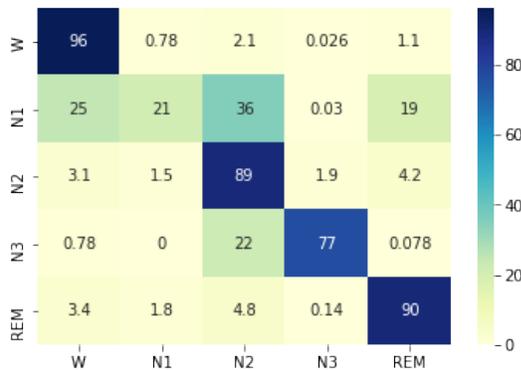


Figura 3. Matriz de confusión para la clasificación del conjunto de test utilizando el *ensemble* de los 5 mejores modelos.

## V. DISCUSIÓN Y CONCLUSIONES

En este trabajo presentamos un *ensemble* de redes convolucionales para la clasificación de fases de sueño. Es una tarea que consume mucho tiempo y crítica a la hora de diagnosticar trastornos del sueño. La mayor parte de los métodos automáticos de clasificación de fases de sueño se basan en características diseñadas para un conjunto de datos concreto y no suelen, por tanto, adaptarse bien a otros conjuntos de datos. Para solucionar este problema usamos una red convolucional que puede aprender las características relevantes de las señales involucradas en la tarea por su cuenta.

Un aspecto importante para el éxito o el fracaso de los modelos convolucionales es la elección correcta de los hiperparámetros. En nuestro caso concreto trabajamos con 4 hiperparámetros, optimizando su selección con un *tree-structured parzen estimator* y evaluando 50 modelos distintos.

El *ensemble* propuesto, a partir de las 5 mejores configuraciones de hiperparámetros, obtiene una precisión, sensibilidad y un *F1 score* medias de 0,78, 0,75 y 0,76 respectivamente, con un índice kappa de 0,83. Aunque globalmente los resultados son aceptables, nuestra solución ha mostrado problemas para clasificar la fase N1. Además, cuando la clasificación es incorrecta suele ser hacia la clase N2.

La comparación frente a trabajos similares es difícil por la falta de estándares, tanto en los conjuntos de datos como en el proceso de evaluación. En la Tabla V mostramos los resultados de trabajos anteriores, limitándonos a los que ofrecen valores para cada clase. Como se puede ver, obtenemos el índice kappa más alto, aunque no los mejores *F1 score*. Salvo para la clase W, algún trabajo presenta mejor *F1 score*. De cualquier manera, los valores que obtenemos son competitivos, con la excepción de la clase N1, aunque queda claro en la comparación que dicha clasificación es la más difícil. Frente al único trabajo que presenta resultados con un conjunto de datos similar [23], obtenemos mejor índice Kappa y *F1 score* para la clase W, con valores casi idénticos para N2, N3 y REM aunque bastante más bajos para N1.

Los resultados son prometedores y el método escogido debería ser adaptable a otros conjuntos de datos, especialmente si además se puede adaptar el entrenamiento. Además, entrenando simultáneamente con varios conjuntos de datos la red debería generalizar mejor, evitando especializarse en registros concretos.

Para mejorar estos resultados es necesario explicar como se hace la clasificación. Además, sería interesante introducir memoria en el modelo, posiblemente en forma de red recurrente, porque en ciertas condiciones, la clasificación de un epoch depende de los epochs anteriores.

## BIBLIOGRAFÍA

- [1] M. M. Ohayon and T. Sagales, "Prevalence of insomnia and sleep characteristics in the general population of Spain." *Sleep medicine*, vol. 11, no. 10, pp. 1010–8, dec 2010.
- [2] J. Marin *et al.*, "Prevalence of sleep apnoea syndrome in the Spanish adult population," *International Journal of Epidemiology*, vol. 26, no. 2, pp. 381–386, apr 1997.
- [3] H. R. Colten and B. M. Altevogt, *Sleep Disorders and Sleep Deprivation*. Washington, D.C.: National Academies Press, sep 2006, vol. 6, no. 9.

Tabla V  
COMPARACIÓN DE RESULTADOS DE TRABAJOS PREVIOS PARA LA CLASIFICACIÓN DE FASES DEL SUEÑO.

Trabajo	Conjunto de datos	Kappa	F1 score				
			W	N1	N2	N3	REM
Biswal et al. [22]	Massachusetts General Hospital, 1000 registros	0,77	0,81	<b>0,70</b>	0,77	0,83	<b>0,92</b>
Långkvist et al. [18]	St Vicent's University Hospital, 25 registros	0,63	0,73	0,44	0,65	<b>0,86</b>	0,80
Sors et al. [23]	SHHS, 1730 registros	0,81	0,91	0,43	0,88	0,85	0,85
Supratak et al. [21]	MASS dataset, 62 registros	0,80	0,87	0,60	<b>0,90</b>	0,82	0,89
Supratak et al. [21]	SleepEDF, 20 registros	0,76	0,85	0,47	0,86	0,85	0,82
Tsinalis et al. [19]	SleepEDF, 39 registros	0,71	0,72	0,47	0,85	0,84	0,81
Tsinalis et al. [20]	SleepEDF, 39 registros	0,66	0,67	0,44	0,81	0,85	0,76
This work	SHHS, 500 registros	<b>0,83</b>	<b>0,95</b>	0,27	0,88	0,84	0,86

- [4] R. B. Berry *et al.*, “AASM Scoring Manual Updates for 2017 (Version 2.4).” *Journal of clinical sleep medicine : JCSM : official publication of the American Academy of Sleep Medicine*, vol. 13, no. 5, pp. 665–666, may 2017.
- [5] Á. Fernández-Leal *et al.*, “A knowledge model for the development of a framework for hypnogram construction,” *Knowledge-Based Systems*, vol. 118, pp. 140–151, 2017.
- [6] C. Stepnowsky *et al.*, “Scoring accuracy of automated sleep staging from a bipolar electroocular recording compared to manual scoring by multiple raters.” *Sleep medicine*, vol. 14, no. 11, pp. 1199–207, nov 2013.
- [7] Y. Wang *et al.*, “Evaluation of an automated single-channel sleep staging algorithm.” *Nature and science of sleep*, vol. 7, pp. 101–11, 2015.
- [8] L. Fraiwan *et al.*, “Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier,” *Computer Methods and Programs in Biomedicine*, vol. 108, no. 1, pp. 10–19, oct 2012.
- [9] J. Liang *et al.*, “Predicting seizures from electroencephalography recordings: A knowledge transfer strategy,” in *Proceedings - 2016 IEEE International Conference on Healthcare Informatics, ICHI 2016*. IEEE, oct 2016, pp. 184–191.
- [10] A. R. Hassan and M. I. H. Bhuiyan, “A decision support system for automatic sleep staging from EEG signals using tunable Q-factor wavelet transform and spectral features,” *Journal of Neuroscience Methods*, vol. 271, pp. 107–118, sep 2016.
- [11] R. Sharma, R. B. Pachori, and A. Upadhyay, “Automatic sleep stages classification based on iterative filtering of electroencephalogram signals,” *Neural Computing and Applications*, vol. 28, no. 10, pp. 2959–2978, oct 2017.
- [12] B. Koley and D. Dey, “An ensemble system for automatic sleep stage classification using single channel EEG signal,” *Computers in Biology and Medicine*, vol. 42, no. 12, pp. 1186–1195, 2012.
- [13] T. Lajnef *et al.*, “Learning machines and sleeping brains: Automatic sleep stage classification using decision-tree multi-class support vector machines,” *Journal of Neuroscience Methods*, vol. 250, pp. 94–105, jul 2015.
- [14] C.-S. Huang *et al.*, “Knowledge-based identification of sleep stages based on two forehead electroencephalogram channels,” *Frontiers in Neuroscience*, vol. 8, p. 263, sep 2014.
- [15] S. Günes, K. Polat, and S. Yosunkaya, “Efficient sleep stage recognition system based on EEG signal using k-means clustering based feature weighting,” *Expert Systems with Applications*, vol. 37, no. 12, pp. 7922–7928, dec 2010.
- [16] A. Esteva *et al.*, “Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 542, no. 7639, pp. 115–118, feb 2017.
- [17] V. Gulshan *et al.*, “Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs,” *JAMA*, vol. 316, no. 22, p. 2402, dec 2016.
- [18] M. Långkvist *et al.*, “Sleep Stage Classification Using Unsupervised Feature Learning,” *Advances in Artificial Neural Systems*, vol. 2012, pp. 1–9, 2012.
- [19] O. Tsinalis *et al.*, “Automatic sleep stage scoring with single-channel eeg using convolutional neural networks,” oct 2016.
- [20] O. Tsinalis, P. M. Matthews, and Y. Guo, “Automatic sleep stage scoring using time-frequency analysis and stacked sparse autoencoders,” *Annals of Biomedical Engineering*, vol. 44, no. 5, pp. 1587–1597, may 2016.
- [21] A. Supratak *et al.*, “Deepsleepnet: A model for automatic sleep stage scoring based on raw single-channel eeg,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25, no. 11, pp. 1998–2008, nov 2017.
- [22] S. Biswal *et al.*, “Sleepnet: Automated sleep staging system via deep learning,” jul 2017.
- [23] A. Sors *et al.*, “A convolutional neural network for sleep stage scoring from raw single-channel EEG,” *Biomedical Signal Processing and Control*, vol. 42, pp. 107–114, apr 2018.
- [24] S. F. Quan *et al.*, “The sleep heart health study: Design, rationale, and methods,” *Sleep*, vol. 20, no. 12, pp. 1077–1085, dec 1997.
- [25] M. H. Bonnet *et al.*, “EEG arousals: scoring rules and examples: a preliminary report from the Sleep Disorders Atlas Task Force of the American Sleep Disorders Association.” *Sleep*, vol. 15, no. 2, pp. 173–184, apr 1992.
- [26] V. Afonso *et al.*, “Ecg beat detection using filter banks,” *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 2, pp. 192–202, 1999.
- [27] I. Fernández-Varela *et al.*, “A simple and robust method for the automatic scoring of EEG arousals in polysomnographic recordings,” *Computers in Biology and Medicine*, vol. 87, pp. 77–86, aug 2017.
- [28] Y. Le Cun *et al.*, “Handwritten digit recognition: applications of neural network chips and automatic learning,” *IEEE Communications Magazine*, vol. 27, no. 11, pp. 41–46, nov 1989.
- [29] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” 2015.
- [30] V. Nair and G. E. Hinton, “Rectified Linear Units Improve Restricted Boltzmann Machines,” *Proceedings of the 27th International Conference on Machine Learning*, no. 3, pp. 807–814, 2010.
- [31] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” dec 2014.
- [32] J. Bergstra *et al.*, “Algorithms for hyper-parameter optimization,” in *NIPS*, 2011.
- [33] J. Bergstra, D. Yamins, and D. D. Cox, “Hyperopt: A python library for optimizing the hyperparameters of machine learning algorithms,” in *Proc. of the 12th python in science conf*, 2013.



# Evaluación de estrategias de binarización en la clasificación de imágenes usando deep learning

Francisco Pérez, Siham Tabik, Alberto Castillo, Hamido Fujita\* y Francisco Herrera  
Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad de Granada,

Granada, España

{fperezhernandez,siham}@ugr.es,{albertocl,herrera}@decsai.ugr.es

\*Iwate Prefectural University, Takizawa, Iwate, Japan

**Resumen**—El reconocimiento de objetos pequeños en imágenes con redes neuronales convolucionales (CNNs) sigue siendo un reto, especialmente cuando estos objetos se manipulan con la mano de forma muy similar. En este trabajo proponemos dividir un problema multiclase del ámbito de la seguridad en un problema de binarización de clases para obtener un mejor resultado. Nuestro objetivo ha sido obtener el mejor modelo de aprendizaje que distinga entre 6 clases, pistolas, smartphone, billete, monedero, tarjeta y background. Concretamente, evaluamos las técnicas *One-Versus-All* (OVA), *One-Versus-One* (OVO) y *Distance-based Relative Competence Weighting combination para OVO* (DRCW-OVO) basadas en CNNs. El mejor rendimiento se obtiene usando DRCW-OVO con una precisión de 90,47 %, un recall del 90,93 % y un F1 del 90,59 %. Esto significó una mejora del 2,58 % en precisión, 1,48 % en recall y 2,13 % en F1 frente a un multclasificador normal.

**Index Terms**—Clasificación, Convolutional Neuronal Networks (CNNs), Multclasificación, Deep Learning, Machine Learning, *One-Versus-All* (OVA), *One-Versus-One* (OVO), DRCW-OVO, ResNet-101

## I. INTRODUCCIÓN

La tarea de clasificar imágenes es un reto en nuestros días y se puede ver en la rama de visión por computador. En competiciones como ImageNet [1], cada año participan muchos equipos de diferentes grandes empresas como Google, y la diferencia para obtener los mejores resultados es crucial.

En el paradigma de *machine learning* clásico, la clasificación es un problema bien conocido donde implementar nuevas técnicas para mejorar los resultados. Es el caso de la descomposición de un problema multiclase en problemas biclase. La clásica técnica *One-Versus-All* (OVA) y *One-Versus-One* (OVO) se usa en muchos trabajos como un buen instrumento para aumentar el rendimiento de los modelos.

ImageNet y COCO (*Common Objects in Context*) [2], abordan un problema de clasificación de imágenes. Concretamente, la tarea es diferenciar objetos cotidianos que pueden provocar una confusión entre ellos. Un problema bien conocido por nuestro grupo de investigación es la detección de armas de fuego. Este tipo de imágenes suponen un reto ya que hay muchos objetos que se pueden manejar de la misma forma.

La mayoría de trabajos anteriores en este ámbito abordaban la detección de armas en imágenes de rayos X, milimétricas o RGB utilizando métodos clásicos de *machine learning* que requieren una alta intervención humana [3], [4], [5], [6], [7].

Actualmente, los modelos más precisos en la clasificación de imágenes y detección de objetos se basan en redes neuronales convolucionales profundas (CNNs) [8]. Estos modelos aprenden automáticamente las características distintivas de los objetos a partir de un gran conjunto de datos etiquetados.

Por lo que sabemos, el primer modelo de detección automática de pistolas en vídeo basado en CNNs fue desarrollado por Olmos et al en [9]. Sin embargo, cuando en los vídeos, una persona manipula objetos como smartphone, billete, monedero o tarjeta, el modelo produce falsos positivos. La Figura 1 muestra ejemplos de este tipo de falsos positivos cometidos por el modelo de detección. Esto puede explicarse por el hecho de que el modelo aprendió la forma en que se manejan las pistolas, siendo también una característica clave, lo cual es intolerable en el campo de la videovigilancia debido a todas las posibles falsas alarmas que se puedan producir.

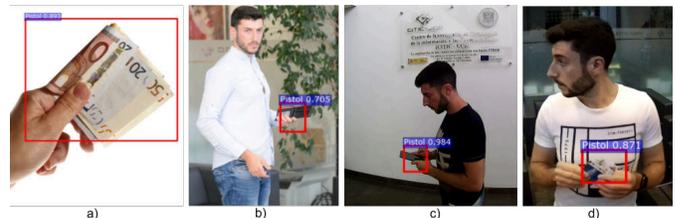


Figura 1. Falsos positivos cometidos por el modelo de detección, donde se confunde con a) billete, b) monedero, c) smartphone y d) tarjeta.

Para mejorar la precisión y robustez del modelo, (1) construimos un conjunto de datos de entrenamiento de alta calidad que incluye todas las clases de objetos posibles que se manejan comúnmente de manera similar, (2) desarrollamos un modelo de clasificación robusto y (3) mejoramos la robustez usando técnicas de *machine learning* como OVA y OVO [10]. Además, el método *Distance-based Relative Competence Weighting combination para OVO* (DRCW-OVO) [11], para problemas multiclase, es utilizado como una extensión de los métodos clásicos de agregación de OVO. Por lo tanto, nos centramos en la tarea de clasificación, ya que es la base de la detección. De hecho, los modelos de detección más influyentes combinan un modelo de clasificación con un método de búsqueda de regiones [12], [13], [14].

Este trabajo se organiza analizando, en la Sección II, los preliminares, donde se analizan trabajos relacionados y las

estrategias de descomposición en problemas multiclase. En la sección III la construcción de la base de datos. La evaluación de las estrategias usadas se encuentra en la sección IV y finalmente las conclusiones aparecen en la sección V.

## II. PRELIMINARES

La mayoría de los trabajos analizados hacen uso de OVA y OVO en tareas visuales, reconocimiento de objetos, clasificación de imágenes y segmentación de imágenes, utilizando sólo modelos clásicos como *Support Vector Machine* (SVM), *Linear Discriminant Analysis* (LDA) y *k-Nearest Neighbors* (k-NN). Por ejemplo, en clasificación de imágenes, los autores en [15] analizaron el enfoque OVA y OVO para reducir el espacio de las características en tres dataset bien conocidos, MNIST, *Amsterdam Library of Object Images* (ALOI) y *Australian Sign Language* (Auslan). Para la estimación de la pose en la segmentación de imágenes, los autores en [16] compararon un clasificador individual basado en CNN con OVA y OVO basado en SVM y mostraron que las CNN logran un rendimiento ligeramente mejor que OVA y OVO basados en SVM. De manera similar, en la tarea de clasificación de imágenes *remote sensing*, los autores en [17] también compararon OVA y OVO basados en SVM y 1-NN y concluyeron que OVA proporcionó peores resultados debido al desequilibrio entre clases. Los mejores resultados fueron obtenidos por OVO con SVM. En el reconocimiento facial, los autores de [18] utilizaron un modelo basado en CNN para la extracción de características y un SVM, OVA y OVO para la clasificación. Los mejores resultados fueron obtenidos por CNN en combinación con SVM. Los autores en [19] compararon la técnica *Half-Against-Half* (HAH) con OVA y OVO en la clasificación de imágenes y encontraron que HAH proporciona resultados similares o peores en los puntos de referencia evaluados. Nuestro trabajo se diferencia de todos los anteriores en que mejora la robustez del reconocimiento de objetos que se manejan similarmente utilizando OVA, OVO y DRCW-OVO basados en CNNs. Hasta donde sabemos, ningún trabajo previo aplicó estas técnicas en modelos de Deep Learning para la clasificación de imágenes.

Los problemas de clasificación que involucran múltiples clases son más difíciles de resolver. El enfoque común para abordar este tipo de problemas es reformular el problema original multiclase en un conjunto de problemas binarios de dos clases. Las técnicas más comunes en este contexto son OVA [20] y OVO [21]. En [22] se ofrece una explicación ampliada y completa de todos los posibles métodos de agregación para OVA y OVO. Además, el método DRCW-OVO [11] amplía el clásico OVO utilizando la distancia entre clases.

### II-A. OVA

La estrategia *One-Versus-All* (OVA) reformula el problema de la clasificación multiclase en un conjunto de clasificadores binarios donde cada clasificador aprende cómo distinguir cada clase individual contra el resto de clases juntas. Este enfoque produce tantos clasificadores como el número de clases en el problema original. La predicción final se calcula combinando las predicciones de los clasificadores individuales mediante

un método de agregación denominado *Maximum Confidence Strategy* (MAX). La clase con el mayor número de votos se considera como la clase pronosticada. Formalmente,

$$\text{PredictedClass} = \arg \max_{i=1, \dots, m} r_i$$

, donde  $r_i \in [0, 1]$  es la confianza para la clase  $i$  y  $m$  es el número de clases. En la Figura 2 se ilustra OVA aplicado al problema multiclase considerado en este trabajo.



Figura 2. Proceso OVA.

### II-B. OVO

La estrategia *One-Versus-One* (OVO) reformula el problema multiclase original en tantos problemas binarios como combinaciones posibles entre pares de clases para que cada clasificador aprenda a discriminar entre cada par. Es decir, un problema  $m$ -clases se convertirá en  $m(m-1)/2$  clasificadores y en el caso considerado, con  $m = 6$  clases, se reformulará en 15 clasificadores, como se aprecia en la Figura 3.



Figura 3. Proceso OVO.

El sistema OVO puede utilizar diversas estrategias de agregación como pueden ser *Max-Wins* (VOTE aleatorio o por peso), *Weighted Voting Strategy* (WV), *Learning Valued Preference for Classification* (LVPC), *Preference Relations Solved by Non-Dominance Criterion* (ND), *Classification by Pairwise Coupling* (PC) y *Wu, Lin and Weng Probability Estimates by Pairwise Coupling approach* (PE).

*VOTE random en OVO*: La regla VOTE, también llamada regla *Max-Wins* [23], se considera como la regla básica de decisión en OVO. En este método se repasa la matriz y en el elemento  $r_{ij}$  si la posibilidad de pertenecer a la clase  $i$  es superior a 0,5, el resultado es la clase  $i$ . Finalmente, se repasa



toda la matriz, se suma el resultado y se selecciona la clase con más votos. Si tenemos dos o más clases con el mismo número de votos, seleccionamos una al azar. Formalmente,

$$\text{PredictedClass} = \arg \max_{i=1, \dots, m} \sum_{i \leq j \neq i \leq m} s_{ij}$$

donde  $s_{ij}$  es 1 si  $r_{ij} > r_{ji}$  y 0 en caso contrario.

*VOTE weight en OVO*: Este es un nuevo enfoque propuesto. En el método VOTE, podemos tener 2 o más clases con los mismos votos. Para las clases con mayor número de votos, proponemos sumar las predicciones y seleccionar la clase con el valor máximo como la clase final.

*WV en OVO*: La técnica *Weighted Voting strategy* pretende obtener la clase con la mayor probabilidad. Por esta razón, cada clase suma sus predicciones y la clase con el valor máximo es el resultado final. La regla de decisión es:

$$\text{PredictedClass} = \arg \max_{i=1, \dots, m} \sum_{i \leq j \neq i \leq m} r_{ij}$$

*LVPC en OVO: Learning Valued Preference for Classification (LVPC)* [24], [25] es la técnica que utiliza el peso de las clases y que penaliza a las clases que no tienen suficiente certeza. La regla de decisión es:

$$P_{ij} = r_{ij} - \min\{r_{ij}, r_{ji}\}; P_{ji} = r_{ji} - \min\{r_{ij}, r_{ji}\}$$

$$C_{ij} = \min\{r_{ij}, r_{ji}\}; I_{ij} = 1 - \max\{r_{ij}, r_{ji}\}$$

$$\text{Class} = \arg \max_{i=1, \dots, m} \sum_{i \leq j \neq i \leq m} P_{ij} + \frac{1}{2} C_{ij} + \frac{N_i}{N_i + N_j} I_{ij}$$

donde  $N_i$  es el número de ejemplos de la clase  $i$  en train.

*ND en OVO*: La técnica *Preference Relations Solved by Non-Dominance Criterion (ND)* se definió originalmente para la toma de decisiones con relaciones de preferencia difusas [26]. En [27] se aplica el mismo criterio en un sistema de clasificación OVO. Primero normalizando, seguido de calcular la preferencia difusa y calcular el grado para cada clase, para obtener la clase final:

$$\bar{r}_{ij} = \frac{r_{ij}}{r_{ij} + r_{ji}}$$

$$r'_{ij} = \begin{cases} \bar{r}_{ij} - \bar{r}_{ji}, & \text{cuando } \bar{r}_{ij} > \bar{r}_{ji} \\ 0, & \text{de otra manera} \end{cases}$$

$$ND_i = 1 - \sup_{j \in C} [r'_{ji}]$$

$$\text{Class} = \arg \max_{i=1, \dots, m} ND_i$$

*PC en OVO*: La técnica *Classification by Pairwise Coupling (PC)* [28] intenta mejorar la estrategia de votación cuando los resultados de los clasificadores son probabilidades estimadas de clase. Este método estima la probabilidad conjunta para todas las clases a partir de las probabilidades de clase por pares de los clasificadores binarios. El algoritmo es:

1. Inicialización:

$$\hat{p}_i = \frac{2 \sum_{1 \leq j \neq i \leq m} r_{ij}}{m(m-1)} \text{ para todo } i = 1, \dots, m$$

$$\hat{\mu}_{ij} = \frac{\hat{p}_i}{\hat{p}_i + \hat{p}_j} \text{ para todo } i, j = 1, \dots, m$$

2. Repetir hasta converger:

$$\hat{p}_i = \hat{p}_i \frac{\sum_{1 \leq j \neq i \leq m} n_{ij} r_{ij}}{\sum_{1 \leq j \neq i \leq m} n_{ij} \hat{\mu}_{ij}} \text{ para todo } i = 1, \dots, m$$

donde  $n_{ij}$  es el número de elementos en train en las clases  $i$ th y  $j$ th.

$$\hat{p}_i = \frac{\hat{p}_i}{\sum_{i=1}^m \hat{p}_i} \text{ para todo } i = 1, \dots, m$$

$$\hat{\mu}_{ij} = \frac{\hat{p}_i}{\hat{p}_i + \hat{p}_j} \text{ para todo } i, j = 1, \dots, m$$

Finalmente, la salida de la clase será:

$$\text{Class} = \arg \max_{i=1, \dots, m} \hat{p}_i$$

*PE en OVO*: La técnica *Wu, Lin y Weng Probability Estimates by Pairwise Coupling Approach (PE)* [29] es similar a PC, estima las probabilidades ( $p$ ) de cada clase a partir de las probabilidades por pares. PE optimiza el siguiente problema:

$$\min_{p} \sum_{i=1}^m \sum_{1 \leq j \neq i \leq m} (r_{ji} p_i - r_{ij} p_j)^2 \text{ sujeto a } \sum_{i=1}^k p_i = 1, p_i \geq 0, \forall i$$

## II-C. DRCW-OVO

*Distance-based Relative Competence Weighting combination* para *One-Versus-One (DRCW-OVO)* en problemas multiclase [11] es una extensión de la técnica OVO que pretende mejorar el problema del desbalanceo de las clases usando la distancia con los  $k$  elementos vecinos a la nueva instancia.

DRCW-OVO, una vez que se ha obtenido la matriz de pesos:

1. Calcular la distancia media de los  $k$  vecinos cercanos a cada clase en el vector  $\mathbf{d}$ .
2. Calcular la nueva matriz de pesos  $R^w$  de la forma:

$$r_{ij}^w = r_{ij} \cdot w_{ij} \text{ donde } w_{ij} = \frac{d_j^2}{d_i^2 + d_j^2}$$

$$r'_{ij} = \begin{cases} \bar{r}_{ij} - \bar{r}_{ji}, & \text{cuando } \bar{r}_{ij} > \bar{r}_{ji} \\ 0, & \text{de otra manera} \end{cases}$$

siendo  $d_i$  la distancia de la instancia a los vecinos cercanos de la clase  $i$ .

3. Usar la estrategia *Weighted Voting (WV)* en la nueva matriz de pesos  $R^w$  para obtener la clase final.

Se ha calculado, para la distancia entre imágenes, la distancia *Quadratic-Chi* [30] con el histograma de las imágenes:

$$X^2(P, Q) = \frac{1}{2} \sum_i \frac{(P_i - Q_i)^2}{(P_i + Q_i)}$$

donde  $P_i$  es el histograma de la nueva instancia y  $Q_i$  es la media del histograma de los  $k$  vecinos cercanos.





Tabla III

PARA OVA MAX, PREDICCIONES, PRECISIÓN, RECALL Y F1 DE CADA CLASE, TESTEADO EN DATASET-TEST.

OVA MAX	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	235	4	8	1	0	95.98 %	83.75 %	89.45 %	
	Billete	5	116	0	1	0	92.80 %	94.30 %	93.54 %	
	Monedero	6	2	90	2	15	0	78.26 %	86.53 %	82.19 %
	Pistola	36	0	1	290	1	2	87.87 %	98.63 %	92.94 %
	Smartphone	13	1	3	0	97	1	84.34 %	84.34 %	84.34 %
	Tarjeta	5	0	2	0	1	58	87.87 %	90.62 %	89.23 %
MEDIA							87.85 %	89.70 %	88.62 %	

de referencia es insignificante. El modelo base entrenado en Dataset-5 obtuvo un precisión de 87,89 %, recall 89,45 % y un F1 88,46 %, mientras que OVA con el método MAX obtuvo un precisión de 87,85 %, recall 89,70 % y F1 88,62 %.

#### IV-B. Estrategia OVO

Nuestro problema es un problema de seis clases, por lo que OVO tendrá quince clasificadores. En la Tabla IV y para cada subtabla, se muestran los resultados de una estrategia de agregación diferente expresado en términos de predicciones, precisión, recall y F1 obtenidos para el test Dataset-Test.

Tabla IV

PARA CADA MÉTODO DE AGREGACIÓN DE OVO, PREDICCIONES, PRECISIÓN, RECALL Y F1 DE CADA CLASE, TESTEADO EN DATASET-TEST.

OVO VOTE random	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	337	3	7	1	1	96.29 %	84.02 %	89.87 %	
	Billete	5	115	1	0	2	93.50 %	93.50 %	93.50 %	
	Monedero	7	4	92	3	12	0	77.97 %	82.88 %	
	Pistola	40	0	2	288	3	1	86.23 %	97.96 %	91.72 %
	Smartphone	8	0	2	2	98	2	87.50 %	85.22 %	86.34 %
	Tarjeta	3	1	0	0	1	58	92.06 %	90.62 %	91.34 %
MEDIA							88.92 %	90.00 %	89.27 %	

OVO VOTE by weight	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	341	4	8	1	1	97.79 %	85.25 %	90.21 %	
	Billete	4	114	1	0	2	94.21 %	92.68 %	93.44 %	
	Monedero	6	4	91	3	11	0	79.13 %	87.50 %	83.11 %
	Pistola	37	0	2	288	3	2	86.75 %	92.68 %	92.01 %
	Smartphone	10	0	2	2	99	1	86.84 %	86.09 %	86.46 %
	Tarjeta	2	1	0	0	1	58	93.55 %	90.62 %	92.06 %
MEDIA							89.38 %	90.02 %	89.55 %	

OVO WV	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	341	5	8	1	1	95.52 %	85.25 %	90.09 %	
	Billete	4	114	0	0	2	95.00 %	92.68 %	93.83 %	
	Monedero	6	3	92	3	11	0	80.00 %	88.46 %	84.02 %
	Pistola	37	0	2	288	3	2	86.75 %	97.96 %	92.01 %
	Smartphone	10	0	2	2	99	1	86.84 %	86.09 %	86.46 %
	Tarjeta	2	1	0	0	1	58	93.55 %	90.62 %	92.06 %
MEDIA							89.61 %	90.18 %	89.75 %	

OVO LVPC	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	342	5	9	2	1	2	94.74 %	85.50 %	89.88 %
	Billete	4	114	0	0	3	2	95.80 %	92.68 %	93.83 %
	Monedero	5	3	91	3	10	0	81.25 %	87.50 %	84.26 %
	Pistola	39	0	2	288	5	2	85.71 %	97.96 %	91.43 %
	Smartphone	8	0	2	1	98	1	89.09 %	85.22 %	87.11 %
	Tarjeta	2	1	0	0	1	57	93.44 %	89.06 %	91.20 %
MEDIA							89.87 %	89.65 %	89.62 %	

OVO ND	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	339	4	7	1	1	1	96.03 %	84.75 %	90.04 %
	Billete	4	114	1	0	0	2	94.21 %	92.68 %	93.44 %
	Monedero	6	4	90	3	11	0	79.35 %	86.54 %	82.97 %
	Pistola	40	0	2	289	3	2	86.01 %	98.30 %	91.75 %
	Smartphone	8	0	4	1	99	1	87.61 %	86.09 %	86.84 %
	Tarjeta	3	1	0	0	1	58	92.06 %	90.62 %	91.34 %
MEDIA							89.15 %	89.83 %	89.33 %	

OVO PC	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	341	5	8	1	1	1	95.52 %	85.25 %	90.09 %
	Billete	4	114	0	0	0	1	95.80 %	92.68 %	94.21 %
	Monedero	6	3	93	3	12	0	79.49 %	89.42 %	84.16 %
	Pistola	38	0	2	288	3	2	86.49 %	97.96 %	91.87 %
	Smartphone	9	0	1	2	98	1	88.29 %	85.22 %	86.75 %
	Tarjeta	2	1	0	0	1	59	93.65 %	92.19 %	92.91 %
MEDIA							89.87 %	90.45 %	90.00 %	

OVO PE	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	339	4	7	1	1	1	95.76 %	84.75 %	89.92 %
	Billete	4	114	0	0	2	0	95.00 %	92.68 %	93.83 %
	Monedero	6	4	91	3	11	0	79.13 %	87.50 %	83.11 %
	Pistola	40	0	2	288	3	2	85.97 %	97.96 %	91.57 %
	Smartphone	8	0	4	1	99	1	87.61 %	86.09 %	86.84 %
	Tarjeta	3	1	0	0	1	58	92.06 %	90.62 %	91.34 %
MEDIA							89.26 %	89.93 %	89.43 %	

Como podemos observar en la Tabla IV, OVO PC supera al resto de métodos, alcanzando unos valores medios de precisión del 89,87 %, recall 90,45 % y F1 90,00 %. Además, OVO PC obtuvo el mejor rendimiento sobre todas las estrategias evaluadas, OVA y el modelo multclasificador base. En particular, OVO PC mejoró el modelo base en un 1,98 % en precisión, un 1 % en recall y un 1,54 % en F1.

#### IV-C. Estrategia DRCW-OVO

DRCW-OVO se evalúa en cuatro valores diferentes de k, el número de vecinos más cercanos que hacen el promedio medio en el valor de la distancia. Los resultados se muestran en la Tabla V. Cada subtabla muestra los resultados de un valor de k diferente expresado en términos de predicciones, precisión, recall y F1 obtenido sobre Dataset-Test.

Tabla V

PARA DISTINTOS VALORES DE K EN DRCW-OVO, PREDICCIONES, PRECISIÓN, RECALL Y F1 DE CADA CLASE, TESTEADO EN DATASET-TEST.

DRCW-OVO k=1	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	347	5	8	2	1	1	95.33 %	86.75 %	90.84 %
	Billete	2	114	0	0	0	1	97.44 %	92.68 %	95.00 %
	Monedero	5	3	91	3	9	0	81.98 %	87.50 %	84.65 %
	Pistola	35	0	2	288	4	1	87.22 %	97.96 %	92.31 %
	Smartphone	8	0	3	1	100	1	88.50 %	86.96 %	87.23 %
	Tarjeta	3	1	0	0	1	60	92.31 %	93.75 %	93.02 %
MEDIA							90.47 %	90.93 %	90.59 %	

DRCW-OVO k=3	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	343	5	9	2	1	9	95.01 %	85.75 %	90.14 %
	Billete	2	114	0	0	0	1	97.44 %	92.68 %	95.00 %
	Monedero	5	3	91	3	11	0	80.53 %	87.50 %	83.87 %
	Pistola	39	0	2	288	4	1	86.23 %	97.96 %	91.72 %
	Smartphone	8	0	2	1	98	1	89.09 %	85.22 %	87.11 %
	Tarjeta	3	1	0	0	1	60	92.31 %	93.75 %	93.02 %
MEDIA							90.10 %	90.48 %	90.14 %	

DRCW-OVO k=5	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	343	5	9	2	1	1	95.01 %	85.75 %	90.14 %
	Billete	2	114	0	0	0	1	97.44 %	92.68 %	95.00 %
	Monedero	5	3	91	3	10	0	81.25 %	87.50 %	83.87 %
	Pistola	39	0	2	288	5	1	85.97 %	97.96 %	91.57 %
	Smartphone	8	0	2	1	98	1	89.09 %	85.22 %	87.11 %
	Tarjeta	3	1	0	0	1	60	92.31 %	93.75 %	93.02 %
MEDIA							90.18 %	90.48 %	90.19 %	

DRCW-OVO k=7	Background	Billete	Monedero	Pistola	Smartphone	Tarjeta	Precisión	Recall	F1	
Predicción	Background	341	5	9	2	1	1	94.99 %	85.25 %	89.86 %
	Billete	3	114	0	0	0	1	96.61 %	92.68 %	94.61 %
	Monedero	5	3	91	3	9	0	81.98 %	87.50 %	84.65 %
	Pistola	40	0	2	288	5	1	85.71 %	97.96 %	91.43 %
	Smartphone	8	0	2	1	99	1	89.19 %	86.09 %	87.61 %
	Tarjeta	3	1	0	0	1	60	92.31 %	93.75 %	93.02 %
MEDIA							90.13 %	90.54 %	90.20 %	

Como podemos observar en esta Tabla V, el método DRCW-OVO con valor k de uno, obtuvo el mejor resultado sobre todos los OVO evaluados, OVA y el modelo multclasificador base. Esta configuración de DRCW-OVO ha obtenido un precisión media de 90.47 %, recall 90.93 % y F1 90.59 %. Esta técnica mejoró el modelo multclasificador base en un 2,58 % en precisión, 1,48 % recall y 2,13 % F1. Esta mejora, con el alto valor de las medidas obtenidas, puede suponer un incremento importante en los resultados de la clasificación.

#### V. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo, proponemos el uso de técnicas de binarización como OVA y OVO para mejorar los resultados de una CNN normal en la tarea de clasificación. Por esta razón, y con la experiencia en este tipo de situaciones, utilizamos un conjunto de datos formado por armas de fuego y otros objetos que se manejan de forma similar. Los pasos realizados fueron, (1) incluir las clases de objetos que pueden suponer una confusión para el modelo como smartphone, billete, monedero y tarjeta, y añadir imágenes con más calidad y contexto a la base de datos utilizando distintas cámaras y contextos, (2) utilizar un nuevo modelo de clasificación como ResNet-101 y (3) mejorar la robustez utilizando técnicas de *machine learning* como OVA, OVO y DRCW-OVO.

Los resultados obtenidos del modelo entrenado en Dataset-5 y testeado sobre Dataset-Test obtienen una mejora de rendimiento de 35.7 % en precisión, 8.7 % recall y 28.05 % F1. Dataset-5 se usa para entrenar los modelos OVA, OVO y DRCW-OVO y los resultados del mejor modelo fueron de

90.47 % en precisión, recall de 90.93 % y F1 de 90.59 % para la técnica DRCW-OVO  $k=1$ . En resumen, hemos alcanzado una mejora del 2,58 % en precisión, del 1,48 % en recall y del 2,13 % en F1. Esto significa que, DRCW-OVO obtiene el valor más alto sobre todas las estrategias evaluadas.

Nuestro trabajo futuro consistirá en estudiar otros objetos que impliquen conflictos. Además, se hará un filtro para las instancias ruidosas que pueden causar confusión en los modelos CNN.

#### AGRADECIMIENTOS

Este trabajo esta parcialmente respaldado por el Ministerio de Ciencia y Tecnología de España, en el proyecto TIN2017-89517-P y por la Junta de Andalucía en el proyecto P11-TIC-7765. Siham Tabik fue apoyada por el programa Ramon y Cajal (RYC-2015-18136) y Francisco Pérez por el Programa de personal técnico financiado por el programa operativo de empleo juvenil. Las Titan X Pascal usadas para esta investigación han sido donadas por NVIDIA Corporation.

#### REFERENCIAS

- [1] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*. IEEE, 2009, pp. 248–255.
- [2] T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and C. L. Zitnick, "Microsoft coco: Common objects in context," in *European conference on computer vision*. Springer, 2014, pp. 740–755.
- [3] G. Flitton, T. P. Breckon, and N. Megherbi, "A comparison of 3d interest point descriptors with application to airport baggage object detection in complex ct imagery," *Pattern Recognition*, vol. 46, no. 9, pp. 2420–2436, 2013.
- [4] A. Glowacz, M. Kmiec, and A. Dziech, "Visual detection of knives in security applications using active appearance models," *Multimedia Tools and Applications*, vol. 74, no. 12, pp. 4253–4267, 2015.
- [5] R. K. Tiwari and G. K. Verma, "A computer vision based framework for visual gun detection using harris interest point detector," *Procedia Computer Science*, vol. 54, pp. 703–712, 2015.
- [6] I. Uroukov and R. Speller, "A preliminary approach to intelligent x-ray imaging for baggage inspection at airports," *Signal Processing Research*, vol. 4, pp. 1–11, 2015.
- [7] Z. Xiao, X. Lu, J. Yan, L. Wu, and L. Ren, "Automatic detection of concealed pistols using passive millimeter wave imaging," in *Imaging Systems and Techniques (IST), 2015 IEEE International Conference on*. IEEE, 2015, pp. 1–4.
- [8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [9] R. Olmos, S. Tabik, and F. Herrera, "Automatic handgun detection alarm in videos using deep learning," *Neurocomputing*, 2017.
- [10] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, and F. Herrera, "An overview of ensemble methods for binary classifiers in multi-class problems: Experimental study on one-vs-one and one-vs-all schemes," *Pattern Recognition*, vol. 44, no. 8, pp. 1761–1776, 2011.
- [11] M. Galar, A. Fernández, E. Barrenechea, and F. Herrera, "Drcw-ovo: distance-based relative competence weighting combination for one-vs-one strategy in multi-class problems," *Pattern recognition*, vol. 48, no. 1, pp. 28–42, 2015.
- [12] S. Ren, K. He, R. Girshick, and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks," in *Advances in neural information processing systems*, 2015, pp. 91–99.
- [13] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, "Ssd: Single shot multibox detector," in *European conference on computer vision*. Springer, 2016, pp. 21–37.
- [14] J. Dai, Y. Li, K. He, and J. Sun, "R-fcn: Object detection via region-based fully convolutional networks," in *Advances in neural information processing systems*, 2016, pp. 379–387.
- [15] A. Rocha and S. K. Goldenstein, "Multiclass from binary: Expanding one-versus-all, one-versus-one and ecoc-based approaches," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 2, pp. 289–302, 2014.
- [16] M. Yu, L. Gong, and S. Kollias, "Computer vision based fall detection by a convolutional neural network," in *Proceedings of the 19th ACM International Conference on Multimodal Interaction*. ACM, 2017, pp. 416–420.
- [17] X. Chen, T. Fang, H. Huo, and D. Li, "Measuring the effectiveness of various features for thematic information extraction from very high resolution remote sensing imagery," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 9, pp. 4837–4851, 2015.
- [18] K. Öztürk and M. B. Yilmaz, "A comparison of classification approaches for deep face recognition," in *Computer Science and Engineering (UBMK), 2017 International Conference on*. IEEE, 2017, pp. 227–232.
- [19] H. Lei and V. Govindaraju, "Half-against-half multi-class support vector machines," in *International Workshop on Multiple Classifier Systems*. Springer, 2005, pp. 156–164.
- [20] P. Clark and R. Boswell, "Rule induction with cn2: Some recent improvements," in *European Working Session on Learning*. Springer, 1991, pp. 151–163.
- [21] S. Knerl, L. Personnaz, and G. Dreyfus, "Single-layer learning revisited: a stepwise procedure for building and training a neural network," in *Neurocomputing*. Springer, 1990, pp. 41–50.
- [22] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, and F. Herrera, "Aggregation schemes for binarization techniques methods' description," *Pamplona, Spain*, 2011.
- [23] J. Friedman, "Another approach to polychotomous classification," Technical report, Department of Statistics, Stanford University, Tech. Rep., 1996.
- [24] E. Hüllermeier and K. Brinker, "Learning valued preference structures for solving classification problems," *Fuzzy Sets and Systems*, vol. 159, no. 18, pp. 2337–2352, 2008.
- [25] J. C. Hühn and E. Hüllermeier, "Fr3: A fuzzy rule learner for inducing reliable classifiers," *IEEE Transactions on Fuzzy Systems*, vol. 17, no. 1, pp. 138–149, 2009.
- [26] S. Orlovsky, "Decision-making with a fuzzy preference relation," in *Readings in Fuzzy Sets for Intelligent Systems*. Elsevier, 1993, pp. 717–723.
- [27] A. Fernández, M. Calderón, E. Barrenechea, H. Bustince, and F. Herrera, "Enhancing fuzzy rule based systems in multi-classification using pairwise coupling with preference relations," *EUROFUSE*, vol. 9, pp. 39–46, 2009.
- [28] T. Hastie and R. Tibshirani, "Classification by pairwise coupling," in *Advances in neural information processing systems*, 1998, pp. 507–513.
- [29] T.-F. Wu, C.-J. Lin, and R. C. Weng, "Probability estimates for multi-class classification by pairwise coupling," *Journal of Machine Learning Research*, vol. 5, no. Aug, pp. 975–1005, 2004.
- [30] O. Pele and M. Werman, "The quadratic-chi histogram distance family," in *European conference on computer vision*. Springer, 2010, pp. 749–762.
- [31] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [32] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard *et al.*, "Tensorflow: A system for large-scale machine learning," in *OSDI*, vol. 16, 2016, pp. 265–283.



# Deep Learning for Fake News Classification

Miguel Molina-Solana  
Data Science Institute  
Imperial College London  
London, UK  
m.molina-solana@imperial.ac.uk

Julio Amador  
Business School  
Imperial College London  
London, UK  
j.amador@imperial.ac.uk

Juan Gómez Romero  
Dept Computer Science and AI  
Universidad de Granada  
Granada, Spain  
jgomez@decsai.ugr.es

**Abstract**—This work presents the application of several Deep Learning techniques for Natural Language Processing to the classification of tweets into containing fake news or not. To validate our approach, we use an open-access dataset containing annotated tweets related to the 2016 US elections. From our experiments, we can confirm that Deep Learning techniques are indeed able to identify tweets containing fake news, and that LSTMs with pre-computed embeddings is the best performing among the tested techniques (validation AUC = 0.70), particularly in avoiding misclassification of the minority class.

**Index Terms**—deep learning, fake news, 2016 US elections

## I. INTRODUCTION

Since the 2016 US elections, the term ‘fake news’ has become mainstream and is nowadays commonly used to refer to pieces of information that are misleading, controversial or plainly inaccurate. This explosion has brought the attention of academics and practitioners from several fields, in an attempt to better understand the phenomenon and its causes.

Although the concept of fake news —as deliberately misleading pieces of information— is nothing new, the wide availability of social networking, publishing platforms, and general access to communication tools, has enabled their ultimate wide-spreading, overtaking the usual process of editorial curating.

Surprisingly enough, the acute characterization of fake news and its proper definition is elusive, remaining a fundamental question to be answered [11]. Cultural backgrounds, previous knowledge and ultimate interpretation of motives behind fake news play a prominent role on the interpretation of what it is and what it isn’t a fake news, with plenty of academics sidelining the difficulty by focusing on the simpler issue of *false news* (to refer to those that have been fact-checked).

While diverse, the reasons for promoting fake news get often reduced to two [3]: pecuniary and ideological. Their impact, if widely embraced, believed and shared, can indeed be quite high as suggested by several pundits and academics in relation to the US presidential election [10].

With fake news becoming commonplace and being cheap to be generated, tools to flag controversial pieces of information are most welcome. Some approaches to identify fake news and their effects on behaviour have been suggested [8]. However, the question of how viral fake news effectively differ from other type of viral content remains unanswered.

Although focused on news stories and their mentions in tweets, a recent study from Vosoughi et al. [16] offers some insights as to how false news (as opposed to fact-checked verified news) might get spread. In particular, they report that falsehood diffused farther and faster than the truth despite structural elements of the network, not because of them.

On the other hand, Deep Learning models and techniques have demonstrated great performance and a very high potential in the recognition of complex patterns in several fields, especially in Computer Vision and Natural Language Processing. These models, which closely resemble the organization of neurons in the brain, mark the evolution of Neural Networks in an era of large data and very high computational power.

Neural Networks perform a non-linear transformation of the input values to the output values by means of several layers of interconnected computing units —i.e. the neurons. Their key approach is achieving learning by example: they take a (large) set of samples as training data, usually with already known labels, and automatically extract the relevant features that can be used to distinguish among classes, thus yielding a model able to classify new unknown samples. To do so, the training process applies an optimization algorithm to adjust the model parameters in order to minimize the network error.

In this context, it looks sensible to apply Deep Learning techniques to the task of classifying unseen pieces of information into containing fake news or not. The work reported here precisely looks into this, trying to offer some insights into the validity of this idea and its ultimate performance.

The paper is organized as follows. Next section introduces the dataset and algorithms we have used for the study. Section III presents the different experiments we carried out and their results and implications. The work finalizes with some pointers for further work.

## II. MATERIALS AND METHODS

To test our hypothesis, we used a dataset containing tweets collected during 4 months just after the 2016 US presidential election [5], starting on November 8th. This dataset includes tweets that got re-tweeted more than 1000 times, and offer two sets of manual annotations for each tweet into fake news or not (Table I), attending to the categories established by [8]. For simplicity, the rest of this paper will consider a tweet as *fake* if it has been labeled as such by at least one annotator of the first or second team.

		2nd Label		
		Other Tweets	Fake News	Unknown
1st Label	Other Tweets	6482	1444	330
	Fake News	213	133	7
	Unknown	250	98	44

TABLE I  
CONTINGENCY TABLE REPORTING THE DIFFERENCES AND THE  
SIMILARITIES BETWEEN THE LABELLING PERFORMED BY THE TWO  
TEAMS IN THE USED DATASET.

The complete dataset includes 9000 tweets and 20 variables, including the text of the tweet itself. After removing registers with empty values, we have 8336 tweets, with 6445 belonging to the negative class (*not fake*) and 1891 to the positive class (*fake*). Note that this procedure differs from the one reported by [4], which only takes into account the labelling by the second team.

We focus on the task of classifying tweets into fake news or not using tweet contents. The aim of this paper is to explore different approaches to build a classifier capable of tagging unseen viral tweets into fake news or not, and particular, those involving deep learning techniques. To do so, we will also limit ourselves to solely work with the actual textual content of the tweet.

Feed-forward Networks are the most basic and common type of neural networks. In these networks, computation moves in one direction, from the input to the output. The typical model is the perceptron, which defines several layers of fully-connected neurons. Model training is performed by backpropagation, a supervised learning algorithm in which the training loss, obtained as the difference between the expected result and the model output, is minimized after iterative adjustment of the model weight values. How the weights are adjusted is determined by an optimization algorithm such as the gradient descent algorithm—and its variants for large data processing in Deep Learning; e.g. Stochastic Gradient Descent (SGD), RMSProp, Adam, AdaGrad, etc.

Recurrent Neural Networks (RNNs) are a type of networks aimed at processing sequential data. Essentially, this type of networks compute a result not only from an input sample, but also by considering its previous state. Therefore, the model output for two equal samples can be different depending on the state of the network. Typically, RNNs process an input sequence  $x_{t-1}, x_t, \dots$  to produce an output sequence  $o_{t-1}, o_t, \dots$ . Among them, long short-term memory (LSTM) networks [15] are particularly appropriate to deal with data sequences and time series with time lags of unknown size and duration between important events.

Formally, LSTM units are composed of a cell, an input gate, an output gate and a forget gate (see diagram in Figure 1). The cell is responsible for ‘remembering’ values over arbitrary time intervals—hence the word ‘memory’ in LSTM—, which are also passed towards the next units. Internally, the LSTM unit combines the input values, the values received through the input gate and the memory values to calculate the output values and the output gate values, taking as well into consideration

the forget gate values.

Finally, and in order to validate our deep learning models built by following the LSTM approach, we compare their performance against traditional classification algorithms using only meta-data about each tweet and author; i.e. number of retweets, number of friends, etc. Specifically, we will use Random Forests [6], which are known to generally perform well in instance classification problems.

The software used for the experimentation is the R framework. We have used the `caret` package for creation and validation of the Random Forest classifiers [9] and the `randomForest` package for the underlying implementation of the algorithms [12]. For the deep learning techniques, we have used `keras` [1] with the `tensorflow` backend [2].

Due to our dataset being highly unbalanced (as shown in Table I), accuracy is not a proper metric to measure performance of the models. Instead we turn our attention to the ROC (receiver operating characteristic) curve and the AUC (area under the curve) measure, because they give a better overview of how true positive rate and false positive rate trade off.

### III. EXPERIMENTS AND DISCUSSION

#### A. Classification with metadata and Random Forest

In our first experiment, we have used the meta-data columns—all but the tweet text—to classify the tweets by the Random Forest algorithm. To do so, we have removed columns describing tweet id, user id, tweet creation date, and software used to publish the tweet. The ratio of training and validation datasets was set to 80-20%. After exploring a parameter grid through several experiments, parameter `mtry`, representing the number of variables randomly selected at each split of the forest generation process, was set to 4.

The results of this experiment can be seen in Figure 2, which shows the ROC curves of the classifiers trained with: (a) original data; (b) data augmented with the SMOTE algorithm [7]—using 200 and 100 as percentages for upsampling and downsampling, respectively. The threshold value for the class probability is automatically calculated by the `randomForest` package.

The AUC values can be seen in Table II. Results with the original data are unsatisfactory because of the strong bias of the classifier towards the majority class, and hence, the low sensitivity values. For this reason, although the AUC value of the classifier without augmentation is slightly better, we would select the classifier with augmentation as the baseline result to improve (AUC = 0.66, sensitivity = 0.74, specificity = 0.51).

The variable importance of the Random Forest classifier according to Gini measure is shown in Figure 3. The results are consistent with the observations in [4] and [16]: the most descriptive variables are the number of retweets (i.e. the *virality* of the tweet) and the number of followers of the author. Note that other parameters, such as whether the user is verified or not, are not as relevant as they might be expected.

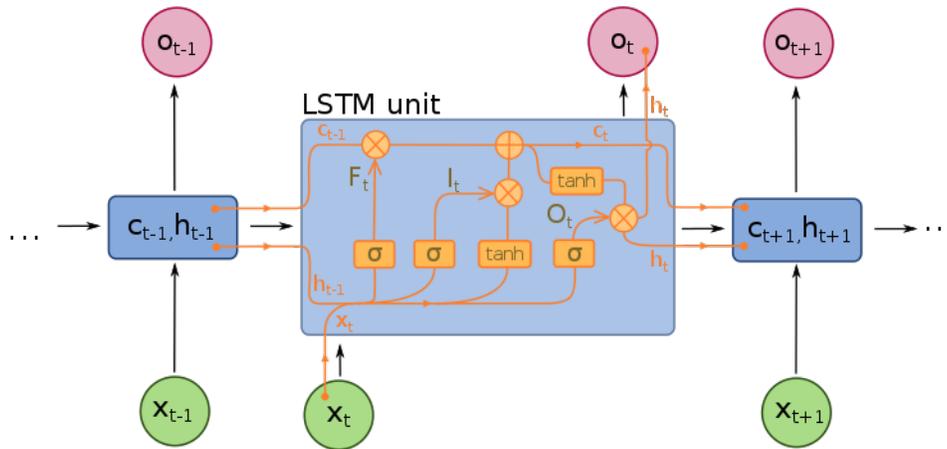


Fig. 1. Diagram of a LSTM unit

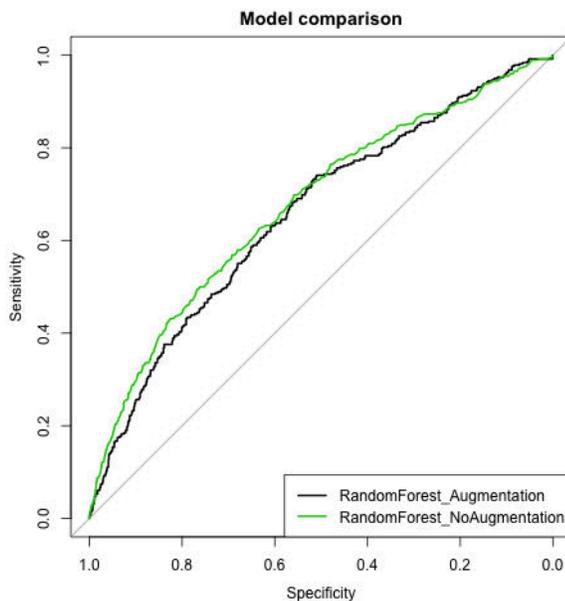


Fig. 2. ROC curves for the Random Forest classifiers

### B. Classification with text and Deep Learning

In the second set of experiments, we have firstly used a feed-forward network to classify tweets from their contents. Secondly, we have implemented a LSTM network. In both cases, it is required to encode the input text into a numeric input, and then train the network to recognize if a tweet is a fake news or not.

There are several alternative approaches to perform the text-to-number encoding. A straightforward approach is one-hot encoding, in which texts are transformed into number vectors after the steps below:

- 1) Tokenize the tweets to extract all the words used in the texts.
- 2) Select the top-k used words ( $k = 10,000$  in our case, from a total number of 21,421 tokens).

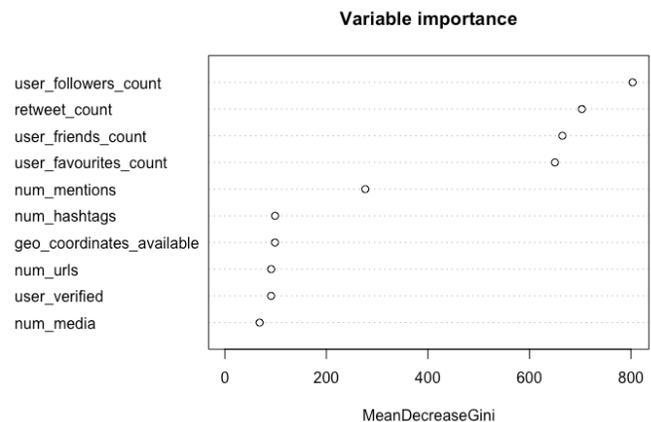


Fig. 3. Variable importance according to the Random Forest model with data augmentation

- 3) Create a binary matrix where each column represents a top-k word and each row represents a tweet. Set the corresponding value  $m_{i,j}$  to 1 if the word  $j$  appears in tweet  $i$ ; otherwise, set it to 0.

This approach has several limitations, in particular because the sparse nature of the encodings resulting after step 3, which makes it difficult to train the classification model. Recently, it has been shown that it is better to encode texts as word embeddings. With this technique, we associate an n-dimension vector with each word, instead of a binary flag. Accordingly, a piece of text is a sequence of n-dimension vectors, being n typically 256, 512 or 1024. The translation from a word to a n-dimension vector is done in a way that the encoding somehow preserves the semantics of the original words; e.g. two encoding vectors corresponding to semantically related words will be close in the embeddings space.

This implies that embeddings must be also learnt in some way; e.g. by using algorithms such as the popular *word2vec* by Mikolov et al. [13]. While learnt word embeddings would be specific of the problem domain, it is common to use pre-

computed embeddings from large text corpora, thus avoiding the problem of reduced input data (as it happens in our problem) and long execution times (which require costly computational resources).

In this paper, we have used the Global Vectors for Word Representation (GloVe) version 1.2 [14]. From the publicly available editions, we have selected glove.6B, which is trained with Wikipedia 2014 and Gigaword 5 news dataset, and the 100-dimension embedding space.

After these considerations, we have performed the following experiments:

- Networks
  - Feed-forward networks (one embedding layer, two hidden layers and an output layer)
    - \* with self-trained embeddings
    - \* with GloVe word embeddings
  - LSTM networks (one embedding layer, a LSTM layer of 32 units and an output layer)
    - \* with self-trained embeddings
    - \* with GloVe word embeddings
- Tokenizer: default Keras `text_tokenizer` function
- Embeddings space size: 100
- Loss function: binary crossentropy
- Optimizer: RMSprop
- Epochs: < 10
- Batch size: 32
- Activation function for hidden layers: ReLU
- Activation function for output layer: sigmoid
- Training / validation: 80%, 20%

Note that, despite the simplicity of the network topologies, overfitting has frequently appeared in the experiments. In such cases, we have used the most accurate network obtained before detecting a significant decrease of the validation performance.

Figure 4 shows the ROC curves for validation of each one of the four models. It can be seen that the best model is the LSTM trained with GloVe word embeddings, which yields an AUC = 0.70 with sensitivity = 0.62 and specificity = 0.68 (see Table II for details).

### C. Discussion

The main result from our work is that LSTM with pre-computed embeddings is the best performer among the techniques we have tested. It is particularly interesting that the ratio of false negatives, the main problem in an unbalanced dataset like ours, obtained with this technique is lower than in the other cases.

However, the overall improvement compared to a Random Forest using tweets' meta-data is not extremely high, as we can see in Figure 5. This poses the question as to how much is worth the extra computation incurred by LSTMs.

More interestingly, a more detailed study of the errors incurred by each model should be performed, in order to identify if both classifiers are orthogonal to some degree. If this is the case, the next step should be to build an ensemble method using these two classifiers, and to determine a proper

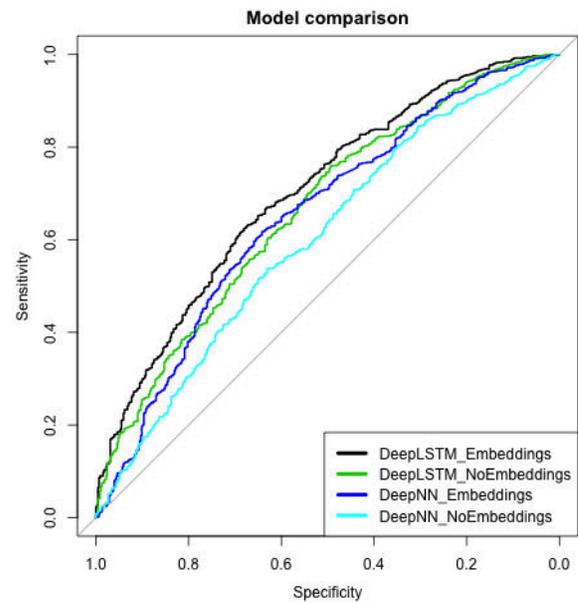


Fig. 4. ROC curves for the Deep Learning classifiers

aggregation function. From our initial studies, we anticipate that double-counting the positive detections (tweets including fake news) could improve the current results.

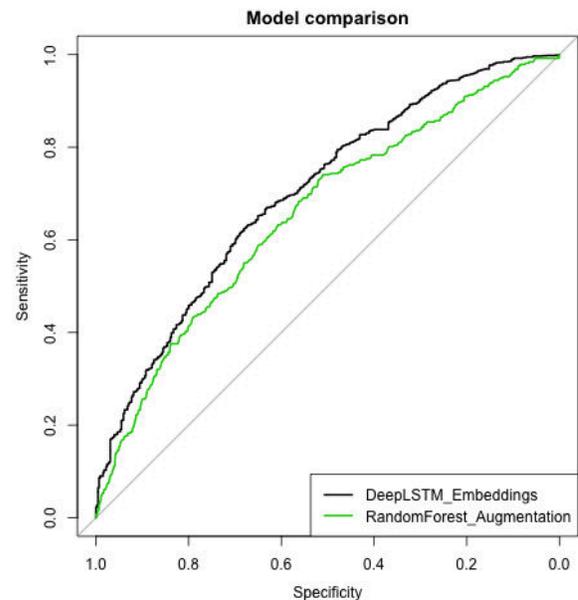


Fig. 5. ROC curves for the two best classifiers

## IV. FUTURE WORK

In this work, we have shown some preliminary results with off-the-shelf deep learning techniques applied to tweets' text in order to identify fake news. Even without a fine-grained adjustment of hyper-parameters nor a long training phase, results are quite promising over the tested dataset.



TABLE II  
EXPERIMENT RESULTS

Algorithm	Version	Training				Validation			
		Accuracy	Sensitivity	Specificity	AUC	Accuracy	Sensitivity	Specificity	AUC
RandomForest	NoAugmentation	1.00	1.00	1.00	1.00	0.71	0.49	0.77	0.68
RandomForest	Augmentation	1.00	1.00	1.00	1.00	0.56	0.74	0.51	0.66
DeepNN	NoEmbeddings	0.99	1.00	0.99	1.00	0.56	0.54	0.63	0.60
DeepNN	Embeddings	0.96	0.98	0.95	1.00	0.62	0.62	0.64	0.65
DeepLSTM	NoEmbeddings	0.95	0.95	0.94	0.99	0.70	0.76	0.49	0.67
DeepLSTM	Embeddings	0.76	0.77	0.76	0.83	0.64	0.62	0.68	0.70

We plan applying more complex Deep Learning models (including a more extensive adjustment of parameters), and couple them together with a text pre-processing stage in order to better clean the text (e.g. currently, we are not considering text elements such as emojis and hyperlinks). It can be also helpful to tune the embeddings representation, either by exploring other pre-calculated transformation or by training on large corpora of only Twitter data.

Furthermore, there seems to be opportunity for ensemble methods that take into account both the meta-data of tweets and their actual text. Adding together the classification capabilities of Random Forests on the meta-data and LSTMs on the text appears as a very promising line of action, which we are currently exploring.

Finally, this study (and hence its results) is tightly coupled to and heavily dependent on the employed dataset. A replication of the experiments on a complementary one is necessary to further validate the current findings strengthening the conclusions and eventually leading to further insights.

All in all, the application of Deep Learning techniques to the task of identifying fake news in social media looks like a very relevant and timely application.

#### ACKNOWLEDGEMENTS

The authors want to thank the support of the Data Science Institute, Imperial College London. M. Molina-Solana is receiving funding from the European Union's Horizon 2020 research and innovation programme under the Marie Skłodowska-Curie grant agreement No 743623. Juan Gómez-Romero is supported by University of Granada under the Young Researchers Fellowship, and received funding from the Spanish Ministry of Education, Culture and Sport under the José Castillejo Research Stays Programme.

#### REFERENCES

- [1] J. Allaire and F. Chollet. *keras: R Interface to 'Keras'*. R package version 2.1.6.9001.
- [2] J. Allaire and Y. Tang. *tensorflow: R Interface to 'TensorFlow'*. R package version 1.5.0.9001.
- [3] H. Allcott and M. Gentzkow. Social media and fake news in the 2016 election. Technical Report 23089, National Bureau of Economic Research, 2017.
- [4] J. Amador, A. Oehmichen, and M. Molina-Solana. Characterizing Political Fake News in Twitter by its Meta-Data. *arXiv*, 2017.
- [5] J. Amador, A. Oehmichen, and M. Molina-Solana. Fakenews on 2016 US elections viral tweets (November 2016 - March 2017). <http://dx.doi.org/10.5281/zenodo.1048826>, 2017.
- [6] L. Breiman. Random forests. *Machine Learning*, 45(1):5–32, 2001.

- [7] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16:321–357, 2002.
- [8] N. J. Conroy, Y. Chen, and V. L. Rubin. Automatic deception detection: Methods for finding fake news. In *Proceedings of the 78th ASIS&T Annual Meeting: Information Science with Impact: Research in and for the Community*, pages 82:1–82:4, 2015.
- [9] M. K. C. from Jed Wing, S. Weston, A. Williams, C. Keefer, A. Engelhardt, T. Cooper, Z. Mayer, B. Kenkel, the R Core Team, M. Benesty, R. Lescarbeau, A. Ziem, L. Scrucca, Y. Tang, C. Candan, and T. Hunt. *caret: Classification and Regression Training*, 2018. R package version 6.0-79.
- [10] R. Gunther, E. C. Nisbet, and P. Beck. Fake news may have contributed to trump's 2016 victory. Technical report, Ohio State University, 2018.
- [11] D. M. J. Lazer, M. A. Baum, Y. Benkler, A. J. Berinsky, K. M. Greenhill, F. Menczer, M. J. Metzger, B. Nyhan, G. Pennycook, D. Rothschild, M. Schudson, S. A. Sloman, C. R. Sunstein, E. A. Thorson, D. J. Watts, and J. L. Zittrain. The science of fake news. *Science*, 359(6380):1094–1096, 2018.
- [12] A. Liaw and M. Wiener. Classification and regression by randomforest. *R News*, 2(3):18–22, 2002.
- [13] T. Mikolov, K. Chen, G. Corrado, and J. Dean. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*, 2013.
- [14] J. Pennington, R. Socher, and C. D. Manning. Glove: Global vectors for word representation. In *Empirical Methods in Natural Language Processing (EMNLP)*, pages 1532–1543, 2014.
- [15] S. H. J. Schmidhuber. Long short-term memory. *Neural Computation*, 9(8):1735–1780, 1997.
- [16] S. Vosoughi, D. Roy, and S. Aral. The spread of true and false news online. *Science*, 359(6380):1146–1151, 2018.

# Procesamiento, análisis y clasificación de neuroimagen con arquitecturas Deep Learning híbridas

Andrés Ortiz<sup>a\*</sup>, Francisco J. Martínez-Murcia<sup>b†</sup>, Jorge Munilla<sup>a‡</sup>, Juan M. Górriz<sup>b§</sup>,  
Javier Ramírez<sup>b¶</sup> and Fermín Segovia<sup>b||</sup>

<sup>a</sup>dept. of Communications Engineering, University of Málaga. Málaga, Spain.

Emails: \*aortiz@ic.uma.es, ‡munilla@ic.uma.es

<sup>b</sup>Dept. of Signal Theory, Networking and Communications, University of Granada, Granada, Spain

Emails: †fjesusmartinez@ugr.es, §gorriz@ugr.es, ¶javierrp@ugr.es, ||fsegovia@ugr.es

**Abstract**—En este trabajo presentamos los últimos trabajos realizados conjuntamente por los grupos SiPBA y BioSiP, donde se han desarrollado diferentes métodos basados en aprendizaje estadístico y Deep Learning para el procesamiento de imágenes cerebrales en diferentes modalidades. Los métodos desarrollados se han aplicado al diagnóstico precoz de enfermedades neurodegenerativas, como la enfermedad de Alzheimer y la enfermedad de Parkinson, proporcionando diferentes representaciones de las imágenes y mejorando las tasas de clasificación de otros sistemas CAD previamente publicados.

**Index Terms**—Deep Learning, Computer aided diagnosis, Alzheimer, Parkinson, statistical processing.

## I. INTRODUCCIÓN

Los nuevos métodos basados en aprendizaje estadístico e inteligencia artificial en combinación con las arquitecturas masivamente paralelas disponibles en la actualidad (unidades de procesamiento gráfico, GPU, por ejemplo) han supuesto una revolución en la forma de abordar el procesamiento de imágenes médicas y en los sistemas de diagnóstico automático. En este trabajo se presentan los últimos métodos desarrollados en los grupos de investigación SiPBA y BioSiP en este sentido, aplicados al procesamiento de imágenes cerebrales estructurales (resonancia magnética, IRM) y funcionales (Tomografía por emisión de positrones, PET o tomografía por emisión de un único fotón, SPECT con diferentes radiofármacos) para el diagnóstico de enfermedades neurológicas y neurodegenerativas como la enfermedad de Alzheimer y Parkinson. En el primer trabajo [1], se muestra un sistema que hibrida el aprendizaje profundo (Deep Learning, DL) con máquinas de soporte vectorial para combinar datos de imagen IRM y PET. En el segundo trabajo [2], se presenta un método para extraer características de una imagen tridimensional a partir de su descomposición en componentes empíricas, utilizando curvas fractales. En el tercer trabajo [3], se muestra una arquitectura que combina varias redes profundas siamesas, para el diagnóstico del Parkinson y finalmente, en [4], se presenta un estudio detallado sobre influencia del preprocesamiento de las imágenes en las redes convolucionales profundas para el diagnóstico del Parkinson.

En los trabajos mencionados se han utilizado imágenes de repositorios internacionales ampliamente utilizados por investigadores de diferentes ámbitos, como el *Alzheimer's Disease Neuroimaging Initiative*, *ADNI* para Alzheimer y *Parkinson Progression Markers Initiative*, *PPMI* para Parkinson.

## II. ENSEMBLES DE ARQUITECTURAS PROFUNDAS PARA EL DIAGNÓSTICO DEL ALZHEIMER

La enfermedad de Alzheimer afecta progresivamente tanto a la estructura del cerebro como a la actividad funcional. La evaluación de ambas requiere modalidades diferentes: en el primer caso, se utilizan imágenes de resonancia magnética y en el segundo, imágenes PET con fluorodeoxiglucosa como radiofármaco. Dado que las imágenes utilizadas son de una resolución considerable y en 3D, el procesamiento de las imágenes completas como es común en 2D no es posible en este caso, debido, fundamentalmente, a los requisitos de memoria. Por otro lado, extraer patrones de imágenes con gran número de voxels, requiere de arquitecturas con un gran número de neuronas y por tanto, muy propensas al sobreentrenamiento. Para solucionar estas dos cuestiones, en [1] se propone definir clasificadores débiles *Deep Belief Networks (DBN)*, sobre cada región neuroanatómica, de acuerdo al atlas AAL. Finalmente, se combinan las predicciones individuales. Se proponen, además, diferentes estrategias de combinación (*ensemble*) de las redes, desde una simple votación por mayoría hasta una votación con pesos calculados a partir de la significancia estadística de los voxels de cada región en el diagnóstico diferencial. También se propone una arquitectura híbrida donde los pesos para la combinación de las predicciones parciales se calculan mediante un el proceso de optimización de un SVM.

## III. EMPIRICAL FUNCTIONAL PCA FOR 3D IMAGE FEATURE EXTRACTION THROUGH FRACTAL SAMPLING. APPLICATION TO PET IMAGE CLASSIFICATION

La idea principal de este trabajo consiste en expresar una imagen de prueba como combinación lineal de un conjunto de imágenes de entrenamiento. Dicho de otra forma, se trata de



representar una imagen en una base formada por un conjunto que contenga imágenes de ambas clases control y Alzheimer). A diferencia de alternativas que utilizan las imágenes completas para determinar una base [6], [8], en este trabajo se utiliza la descomposición empírica de modos (EMD) para obtener una base con una mayor capacidad de representación. La descomposición empírica de modos proporciona un medio para descomponer una imagen en componentes de diferente frecuencia y que por tanto, contienen diferente información. Una descomposición similar puede hacerse mediante análisis de Fourier o de Wavelet. No obstante, ambos métodos utilizan una base predefinida para representar la señal original, mientras que EMD calcula dicha base de forma empírica para la señal a descomponer. Aunque existen extensiones de EMD a 2D que hemos aplicado anteriormente con el mismo propósito que en este trabajo [7], la extensión a 3D no es inmediata y computacionalmente muy costosa. En este trabajo proponemos convertir la imagen 3D en 1D utilizando curvas fractales multidimensionales para muestrear los vóxeles de la imagen. Concretamente curvas de Peano-Hilbert, que tienen la propiedad de conservar la relación espacial entre los puntos de la curva, asegurando que puntos próximos en 3D estarán también próximos en 1D. Una vez descompuesta la señal, se utiliza el algoritmo *Basis Pursuit* para encontrar la mejor representación de la misma en la base sobrecompleta formada por las funciones de modo intrínseco (IMF). Dichas representaciones son finalmente utilizadas para entrenar un SVM.

#### IV. LABEL AIDED DEEP RANKING FOR THE AUTOMATIC DIAGNOSIS OF PARKINSONIAN SYNDROMES

En este trabajo se extiende el método Deep Ranking (DR) con el fin de aplicarlo eficientemente a la clasificación de imágenes DaTSCAN SPECT, y por tanto, al diagnóstico diferencial de la enfermedad de Parkinson. La idea principal de DR es obtener una función que permita proyectar las imágenes 3D en un espacio de dimensión  $\mathbb{R}^n$ . Dicha función se obtiene mediante un proceso de aprendizaje que utiliza una función de pérdida cuya minimización provoca que muestras de la misma clase estén juntas en el espacio de proyección, mientras que muestras de clases diferentes estén lo más separadas posible en dicho espacio, utilizando como métrica la distancia Euclídea. El modelo DR desarrollado, está formado por tres redes siamesas (que comparten la actualización de los pesos). De esta forma, tras la convergencia, las tres redes se comportarán de la misma forma (dado que comparten los pesos optimizados durante el aprendizaje). En este trabajo se han utilizado redes convolucionales 3D en cada bloque que contienen 5 capas de convolución y dos capas *Fully connected* así como regularización mediante *Dropout*.

#### V. CONVOLUTIONAL NEURAL NETWORKS FOR NEUROIMAGING IN PARKINSON'S DISEASE: IS PREPROCESSING NEEDED?

En el campo de la neuroimagen, es una práctica común normalizar las imágenes tanto espacialmente como en inten-

sidad. La normalización espacial se realiza de acuerdo a una plantilla, a través de transformaciones afines para realizar la corrección del movimiento y la reorientación de las imágenes. De esta forma, los vóxeles de todas las imágenes coinciden, refiriéndose a la misma posición neuroanatómica. La normalización en intensidad resulta especialmente útil con imágenes funcionales, donde la mayor parte de la información está en el nivel de activación de los vóxeles. En este trabajo, se realiza un estudio detallado de la influencia de ambas normalizaciones en la clasificación de imágenes DaTSCAN SPECT utilizando redes convolucionales 3D (CNN). Se muestran los resultados obtenidos para diferentes arquitecturas y funciones de activación y coste, analizando también la dispersión de los resultados obtenidos con validación cruzada. Del estudio realizado se concluye que los clasificadores basados en CNN permiten obtener un área bajo la curva ROC muy alta (0.98) sin normalizar espacialmente las imágenes, de forma que es posible evitar este costoso proceso. Sin embargo, la normalización en intensidad sí influye de forma decisiva en las prestaciones del modelo. Por otro lado, la visualización de los patrones de déficit dopaminérgico descubiertos a través de los mapas de saliencia, coinciden con los que aparecen en la literatura para imágenes FP-CIT, validando así la utilidad de la metodología propuesta.

#### ACKNOWLEDGMENT

Este trabajo ha sido parcialmente financiado por MINECO/FEDER bajo los proyectos TEC2015-64718-R and PSI2015-65848-R projects.

#### REFERENCES

- [1] Ortiz, A., Munilla, J., Górriz, J.M. and Ramírez, J., "Ensembles of Deep Learning Architectures for the early diagnosis of Alzheimer's Disease". *International Journal of Neural Systems*. 26(7):1-23. 2016.
- [2] Ortiz, A., Munilla, J., Martínez-Murcia, F., Górriz, J.M. and Ramírez, J., "Empirical Functional PCA for 3D image feature extraction through fractal sampling". *International Journal of Neural Systems*, 2018. Accepted for Publication
- [3] Ortiz, A., Martínez-Murcia F.J., Munilla, J., Górriz J.M. and Ramírez J., "Label Aided Deep Ranking for the automatic diagnosis of Parkinsonian Syndromes.". 2018, submitted.
- [4] Martínez-Murcia, F., Górriz, J.M., J. Ramírez and Ortiz, A. "Convolutional Neural Networks for Neuroimaging in Parkinson's disease: is preprocessing needed?". *International Journal of Neural Systems*, 2018. Accepted for publication
- [5] Ortiz, A., Lozano, F., Górriz, J.M., Ramírez, J., and Martínez-Murcia, F.J., "Discriminative Sparse Features for Alzheimer's Disease Diagnosis using multimodal image data". *Current Alzheimer Research*. 2018;15(1):67-79
- [6] Álvarez, I., Górriz, J.M., Ramírez, J., Salas-Gonzalez, D., López, M., Puntónet, G.C. and Segovia, F. "Alzheimer's diagnosis using eigenbrains and support vector machines". *Electronics Letters*, 2009; 45(7):342-343.
- [7] Rojas, A., Górriz, J.M., Ramírez, J., Illán, A., Martínez-Murcia, F.J., Ortiz, A., and Gómez-Río, M., "Application of Empirical Mode Decomposition (EMD) on DaTSCAN SPECT images to explore Parkinson Disease". *Expert Systems with Applications*. 2013 40(7):2756-2766.
- [8] J.M. Górriz; J. Ramírez; J. Suckling; I.A. Illán; A. Ortiz; F.J. Martínez-Murcia; F. Segovia; D. Salas-González and S. Wang. "Case-based statistical learning: a non parametric implementation with a conditional-error rate SVM". *IEEE Access*, 2017(5):11468-11478.



---

# I Workshop en Deep Learning (DeepL)

SESIÓN 3







# Guiding the Creation of Deep Learning-based Object Detectors\*

Ángela Casado

*Departamento de Matemáticas y Computación  
Universidad de La Rioja  
Logroño, España  
acg181293@hotmail.com*

Jónathan Heras

*Departamento de Matemáticas y Computación  
Universidad de La Rioja  
Logroño, España  
jonathan.heras@unirioja.es*

**Abstract**—Object detection is a computer vision field that has applications in several contexts ranging from biomedicine and agriculture to security. In the last years, several deep learning techniques have greatly improved object detection models. Among those techniques, we can highlight the YOLO approach, that allows the construction of accurate models that can be employed in real-time applications. However, as most deep learning techniques, YOLO has a steep learning curve and creating models using this approach might be challenging for non-expert users. In this work, we tackle this problem by constructing a suite of Jupyter notebooks that democratizes the construction of object detection models using YOLO. The suitability of our approach has been proven with a dataset of stomata images where we have achieved a mAP of 90.91%.

**Index Terms**—Object Detection, YOLO, Jupyter Notebooks.

## I. INTRODUCTION

Object detection is a computer vision area that focuses on identifying the position of multiple objects in an image. Traditionally, object detection methods have been based on two main techniques known as sliding windows and image pyramids; and, they have been successfully applied to solve problems such as face detection [1] or pedestrian detection [2]. However, those approaches are slow, lack the notion of aspect ratio and are error prone [3]. These problems have been recently overcome using deep learning techniques.

Deep learning has impacted almost every area of computer vision, and object detection is no exception. Intuitively, in deep learning-based object detectors, we input an image to a network and obtain, as output, the bounding boxes (that is, the minimum rectangle containing the objects) and the class labels. Deep learning-based object detectors can be split into two groups: one-stage and two-stage object detectors. The former divide the image into regions, that are passed into a convolutional neural network, and then the prediction is obtained — these detectors include techniques such as SSD [4] or YOLO [5]. The two-stage object detectors employ region proposal methods to obtain interesting regions in the image, that are later processed to obtain the prediction — these methods include the R-CNN family of object detectors [6]–[8].

\*This work was partially supported by Ministerio de Economía y Competitividad [MTM2017-88804-P]. We also gratefully acknowledge the support of NVIDIA Corporation with the donation of the Titan Xp GPU used for this research.

Usually, one-stage object detectors are faster but less precise than two-stage object detectors; however, the one-stage object detector YOLO has recently achieved a similar accuracy to the one obtained by two-stage object detectors, but keeping fast processing [5]. Due to this fact, the YOLO object detector has been applied in problems that require real time processing but also need a high accuracy, like real time detection of lung modules [9] or the detection of small objects in satellite imagery [10].

The YOLO object detector is provided as part of the Darknet framework [11]; but, as almost every deep learning tool, it has a steep learning curve and adapting it to work in a particular problem might be a challenge for several users — apart from understanding the underlying algorithm of YOLO (a step that might not be necessary to create an object detection model with YOLO), using YOLO might be a challenge since it requires, among others, the installation of several libraries, the modification of several files and the usage of a concrete file structure. Therefore, even if this technique might be helpful for several fields (ranging from biomedicine and agriculture to security), users from those fields are not able to take advantage of it. To solve this problem, we have developed an assistant, in the form of a suite of Jupyter notebooks, that guides non-expert users through all the steps that are necessary in an object detection project using YOLO.

As we explain in Section II, there are several steps that are required to create a deep learning-based object detector; but, thanks to our assistant, see Section III, they are reduced to fixing a few parameters, and the rest of the process is conducted automatically by our tool. To prove the suitability of our approach, we have employed the assistant to create an stomata detector for plant images, see Section IV. The paper ends with some conclusions and further work.

## II. A PIPELINE TO CREATE DEEP LEARNING-BASED OBJECT DETECTORS

In this section, we present the common workflow to create a deep learning-based object detector (see Figure 1), the challenges that are faced on each stage of the pipeline, the solutions that we propose to deal with those challenges, and the particularities of using the YOLO network in each stage.

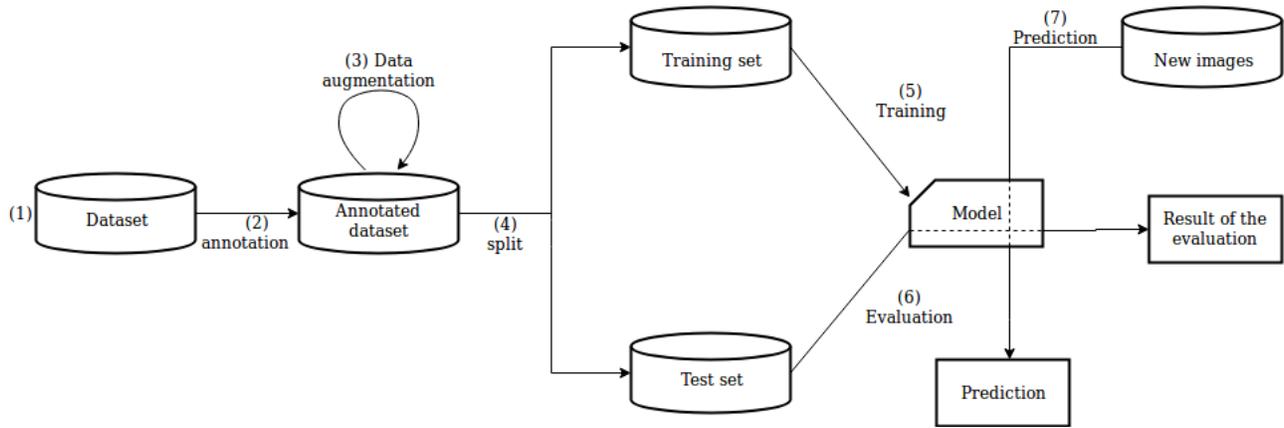


Fig. 1. Workflow of object detection projects

### 1. Dataset acquisition

Independently of the framework employed to create an object detection model, the first step to construct an object detection model is always the acquisition of a dataset of images containing the objects that we want to detect. This task is far from trivial since the dataset must be representative of what the model will find when deployed in the real world; and, therefore, its creation must be carefully undertaken. Moreover, acquiring data in problems related to, for instance, biomedical images might be difficult [12], [13].

There are several ways of obtaining a dataset of images depending on the project, but we can identify four main sources:

- *Open datasets.* There are several projects that have collected a huge amount of images, such as ImageNet [14] or Pascal VOC [15]; however, those datasets might not contain the objects that the user is interested in detecting.
- *Web scraping.* It is quite straightforward to create a program that uses image search engines, such as Google images or Bing images, to download images with a Creative Commons License from the web — this allows us to legally employ those images to create object detectors. Even if this approach can be a fast way of downloading images, it might require data curation to obtain a representative dataset for the intended task.
- *Special purpose datasets.* This approach might be the only option in problems with sensitive data, like in biomedicine, where an external agent (for instant, a hospital) provides the images. The main drawbacks for this approach are the limited number of images, the difficulties to acquire new data, and restrictions related to access and use of the images.
- *Special purpose devices to capture images.* In this case, the images are acquired by using devices that might range from a microscope to a fixed camera in a working environment. This approach has the advantage of dealing with images that are representative of the environment where the model will be later used; and, additionally, it is usually easy to obtain new images. However, the

models created with those images might not be useful if the conditions change. For instance, if a model is created using images acquired with a microscope using a set of fixed conditions, the model might not work as expected if applied to images acquired with a different microscope or under different conditions.

As we have previously mentioned, this step is independent of the tool that is employed to create the object detection model. The only restriction from the YOLO side is that the images must be stored using the JPG format.

### 2. Dataset annotation

Once the images have been acquired, they must be annotated, a task that is time-consuming and might require experts in the field to conduct it properly [16]. In the object detection context, images are annotated by providing a file with the list of bounding boxes and the category of the objects inside those boxes. Those annotation files are not written manually, but they are built using graphical tools like LabelImg [17] or YOLO mark [18]. Unfortunately, there is not a standard annotation format and, in fact, the format varies among object detection frameworks, and also among the annotation tools. Therefore, this must be taken into account when annotating a dataset of images; otherwise, a conversion step will be necessary after the annotation process is completed.

In the case of YOLO, the annotations are provided as plain text files where each bounding box is given by the position of its center, its width and height. It is convenient to use a tool that produces the annotations directly in this format, like YOLO mark [18], but there are also converters from other formats; for instance, from Pascal VOC or Kitti [19].

### 3. Dataset augmentation

As we have previously mentioned, acquiring and annotating datasets of images for object detection problems might be a challenge; this might lead to generalization problems if enough images are not acquired. A successful method that has been applied to deal with the issue of limited amount of data is *data augmentation* [20]. This technique consists in generating



new training samples from the original dataset by applying image transformations (for instance, applying flips, rotations, filters or adding noise). This approach has been applied in image classification problems, and there are several libraries implementing this method (for instance, Augmentor [21] or Imgaug [22]).

The application of data augmentation is not straightforward in the case of object detection due to the fact that, on the contrary to data augmentation in image classification, transformation techniques alter the annotation in the context of object detection. For instance, applying the vertical flip operation to a cat image produces a new cat image — i.e. the class of the image remains unchanged — but the position of the cat in the new image has changed from the original image. Therefore, we have to transform not only the image but also the annotation.

In order to apply data augmentation in object detection, the usual approach has consisted in implementing special purpose methods, depending on the particular problem, or manually annotating artificially generated images. Neither of these two solutions is feasible when dealing with hundreds or thousands of images. To deal with this issue, we can employ the CLoDSA library [23], a tool that can be applied to automatically augment a dataset of images devoted to classification, localization, detection or semantic segmentation using a great variety of the classical image augmentation transformations. Using this tool, it is possible to automatically generate a considerable amount of images, together with their annotations, starting from a small dataset of annotated images. CLoDSA is compatible with the YOLO format.

#### 4. Dataset split

As in any other kind of machine learning project, it is instrumental to split the dataset obtained in the previous steps into two independent sets: a training set — that will be employed to train the object detector — and a test set — that will be employed to evaluate the model. Common split sizes for training and testing set include 66.6%/33.3%, 75%/25%, and 90%/10%, respectively.

In the case of YOLO, the dataset split is achieved by using a particular folder structure to store the images and the labels that will be employed for training and testing, and providing two files that indicate, respectively, the set of images that will be employed for training and testing. It is worth mentioning that the YOLO framework is really sensitive to such a structure, and small changes will prevent the user from training the model.

#### 5. Training the model

Given the training set of images, several tasks remain before starting the process to train an object-detection model. In particular, it is necessary to define the architecture of the model (that is, the number and kind of layers), fix some hyper-parameters (for example, the batch size, the number of epochs, or the momentum) and decide whether the training process starts from scratch or some pre-trained weights are employed

— the latter option, known as fine-tuning, usually improves the training process [24].

The YOLO framework supplies several pre-defined models for training an object detector — the best model, both in terms of accuracy and time efficiency, is the YOLO model v3. The architecture and the hyper-parameters of those models are defined in a configuration file; and, even if the by-default YOLO hyper-parameters usually work properly for training a new model, it is necessary to modify the configuration files since the model architecture must be adapted depending on the number of classes included in the dataset. Once the configuration files have been adapted, the training process can start just by executing a command. The process will end either after the provided number of epochs is reached or when the user decides to manually stop the process. In order to train a YOLO model, it is recommended to use some pre-trained weights that must be downloaded and included in the project [5].

#### 6. Evaluating the model

After training the model, we need to evaluate it to assess its performance. Namely, for each of the images in the testing set, we present it to the model and ask it to detect the objects in the image. Those detections are compared to the ground-truth provided by the annotations of the testing set, and the result of the comparison is evaluated using metrics such as the IoU, the mAP, the precision, the recall or the F1-score [15]. The YOLO framework can perform such an evaluation automatically provided that several configuration files are correctly defined, and the correct instruction is invoked.

A problem that might arise during the evaluation is the overfitting of the object detection model; that is, the model can detect objects on images from the training dataset, but it cannot detect objects on any others images. In order to avoid this problem, *early stopping* [25] can be applied by comparing the results obtained by the models after different numbers of epochs. In the case of YOLO models, early stopping can be applied since the framework saves the state of the model every time that a certain number of training iterations is reached.

#### 7. Deploying the model

Finally, the model is ready to be employed in images that neither belong to the training set nor to the testing set. Even if using the model with new images is usually as simple as invoking a command with the path of the image (and, probably, some additional parameters), it is worth mentioning that it is unlikely that the person who created the object detection model is also the final user of such a model. Therefore, it is important to create simple and intuitive interfaces that might be employed by different kinds of users; otherwise, they will not be able to take advantage of the object detection model.

### III. A SUITE OF JUPYTER NOTEBOOKS

As we have explained in the previous section, training and using a YOLO model involves the creation and modification of several configuration files, the use of a concrete folder

structure, and the execution of several commands; hence, the process is time-consuming and error prone. In this section, we introduce a simple-to-use tool that facilitates the creation of YOLO-based object detectors using Jupyter notebooks — the suite of notebooks can be downloaded from <https://github.com/ancasag/YOLONotebooks>.

Jupyter notebooks [26] are documents for publishing code, results and explanations in a form that is both readable and executable. Jupyter notebooks have been widely adopted across multiple disciplines, both for its usefulness in keeping a record of data analyses, and also for allowing reproducibility. In addition, Jupyter notebooks are a useful tool to teach and learn concepts from data science and artificial intelligence [27], [28]. In our case, we have developed a suite of notebooks that guides the user in the process to create a YOLO-based object detector. The only requirement to run the notebooks is the installation of the programming language Python and its Jupyter library.

The suite of notebooks is open-source and contains several notebooks that introduce several traditional object detection notions, explain how to install the YOLO framework, and provide several examples showing how to use it (for instance, showing how the pre-trained models included in the framework might be used to detect objects in images and videos). However, the most important notebook of the suite is the one that automates the process of creating a new object detection model. Using this notebook, the user only has to (1) create a folder containing the images and the annotations in the YOLO format, and (2) fix 4 parameters in the notebook (the name of the project, the path to the folder containing the images and annotations, the list of classes, and the percentage of the images that will be employed for training); the rest of the process is carried out by simply following the steps included in the notebook. In particular, the notebook is in charge of:

- Validating that the images of the dataset are given in the correct format.
- Checking that all the images of the dataset have their corresponding annotation.
- Guiding the user in the process to augment the dataset of images using the CLoDSA library.
- Splitting the dataset into a training set and testing set, and organizing those sets in the way required by the YOLO framework.
- Creating all the configuration files for training, evaluating and deploying the model using the last version of the YOLO network.
- Generating all the instructions that are required to train, test and deploy the YOLO model.
- Providing a simple way of invoking the generated YOLO model to detect objects in new images.

Without our tool, all those steps should be carried out manually; hence, the burden of creating a YOLO-based object detector is significantly reduced. The aforementioned functionality has been implemented in Python using several third-party libraries such as Scikit-learn [29] and OpenCV [30].

#### IV. CASE STUDY: STOMATA DETECTION

In this section, we show the feasibility of using our tool by creating a stomata detector in images of plant leaves. A stoma is a tiny opening, or pore, that is used for gas exchange in plants. The amount and behavior of stomata provide key information about water stress levels, production ratio, and, in general, the overall health of the plant [31]. Hence, by measuring the number of stomata, it is possible to manage better the resources in agriculture and obtain better yields [32]. However, manually counting the number of stomata is a time-consuming and subjective task due to the considerable amount of stomata in an image, their small size, and the fact that it is necessary to analyze batches of dozens of images. Therefore, it is useful to automatically detect and count the number of stomata in plant images.

Several studies can be found on automatic detection of stomata, but they employ traditional features like Haar [33], MSER [34] or HOG [35] combined with a cascade classifier, and neither the implementation of those techniques nor the datasets of those studies are available, making unfeasible the reproducibility of their results or the use of their models with new images. On the contrary, using the suite of notebooks presented in the previous section, and a dataset of images provided by the University of Missouri, we have built a freely available YOLO-based stomata detector for images of plant leaves.

The dataset employed to construct our model consists of 468 microscope images of the leaf epidermises of different plant types (including cotton, peanut and maize plants), and those images contain a total amount of 1652 stomata — the dataset is available from the authors on request. The images were annotated by expert biologists using the LabelImg program, that produces annotations in the Pascal VOC format; hence, it was necessary to transform those annotation to the YOLO format using a Python script. After storing the images and labels in the same folder, and fixing the 4 parameters explained in the previous section, the following process was conducted guided by the notebook.

First of all, to improve the generalization of the model, the CLoDSA library was employed to augment the dataset of images by employing techniques like flips, rotations, filters and adding noise. The final dataset was formed by a total of 4212 images, enough for training an object detector. Subsequently, the dataset was split into two sets, using 90% of the dataset for training, and 10% for testing — those sets were automatically split, organized in the corresponding folders, and, additionally, all the configuration files were automatically generated. After training the model for 250000 epochs, we stopped the process and evaluated the model using the testing set. The results achieved by the model were a mAP of 90.91%, a precision of 98% and a F1-score of 99%.

This process can be easily reproduced using the notebook available in the project webpage, and the obtained model can be invoked to detect stomata in images that do not belong neither to the training nor the testing set, see Figure 2. The

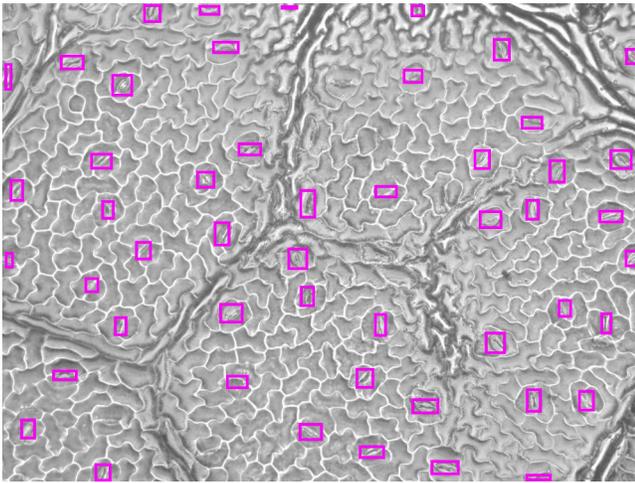


Fig. 2. Stomata identification results

model was trained using a Titan Xp GPU, but it can be employed for detecting stomata in any computer that has Python and C++ installed on it.

## V. CONCLUSIONS AND FURTHER WORK

Democratizing Artificial Intelligence is a movement that has been born with the goal of making artificial intelligence accessible to non-expert users from different fields [36], [37]. The work presented in this paper can be framed in that context; in particular, after carefully analyzing all the steps that are required to construct an object detector using deep learning techniques, we have presented a suite of Jupyter notebooks that allows non-expert users to easily create fast and accurate object-detection models using the YOLO approach — one of the most effective methods for object detection. The suitability of our approach has been tested by developing a model for stomata detection in plant images that achieves a mAP of 90.91%.

In addition to the benefit of simplifying the creation of object detection models, the suite of Jupyter notebooks has value as a teaching material since we have included explanations, both textual and graphical, of all the steps involved in the creation of an object detector; and, hence, they can be useful for Artificial Intelligence and Computer Vision courses.

The main drawback of our suite of plugins is that users need a GPU installed, and properly configured, in their computer, since training deep learning models usually requires the use of a GPU. Therefore, as further work, we plan to integrate our tool in a cloud service like Amazon or Google Cloud to provide a cheap and fast way of constructing object detection models. Moreover, we intend to extend the suite of plugins with other deep learning techniques for object detection, such as SSD or faster R-CNN; and also for other computer vision problems like image classification or semantic segmentation.

## REFERENCES

- [1] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," in *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'01)*, vol. 1, 2001, pp. 511–518.
- [2] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, vol. 1, 2005, pp. 886–893.
- [3] A. Rosebrock, *Deep Learning for Computer Vision with Python*. Py-ImageSearch, 2017.
- [4] W. Liu *et al.*, "Ssd: Single shot multibox detector," in *Proceedings of the 14th European Conference on Computer Vision (ECCV 2016)*, ser. Lecture Notes in Computer Science, vol. 9905, 2016, pp. 21–37.
- [5] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," *CoRR*, vol. abs/1804.02767, 2018. [Online]. Available: <http://arxiv.org/abs/1804.02767>
- [6] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proceedings of the 2014 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'14)*, vol. 1, 2014, pp. 580–587.
- [7] R. Girshick, "Fast R-CNN," in *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV 2015)*, 2015, pp. 1080–1088.
- [8] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," in *Advances in Neural Information Processing Systems*, 2015, vol. 28, pp. 91–99.
- [9] S. Ramachandran, J. George, S. Skaria, and V. V. Varun, "Using yolo based deep learning network for real time detection and localization of lung nodules from low dose ct scans," vol. 10575, 2018, p. 1057511.
- [10] A. V. Etten, "You only look twice: Rapid multi-scale object detection in satellite imagery," *CoRR*, vol. abs/1805.09512, 2018. [Online]. Available: <http://arxiv.org/abs/1805.09512>
- [11] J. Redmon, "Darknet: Open source neural networks in c," 2013. [Online]. Available: <http://pjreddie.com/darknet/>
- [12] E. Valle *et al.*, "Data, Depth, and Design: Learning Reliable Models for Melanoma Screening," *CoRR*, vol. abs/1711.00441, 2017. [Online]. Available: <http://arxiv.org/abs/1711.00441>
- [13] A. Asperti and C. Mastrorardo, "The Effectiveness of Data Augmentation for Detection of Gastrointestinal Diseases from Endoscopic Images," *CoRR*, vol. abs/1712.03689, 2017. [Online]. Available: <http://arxiv.org/abs/1712.03689>
- [14] O. Russakovsky *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211–252, 2015.
- [15] M. Everingham *et al.*, "The PASCAL Visual Object Classes Challenge 2012 (VOC2012) Results," <http://www.pascal-network.org/challenges/VOC/voc2012/workshop/index.html>, 2012.
- [16] X. Wang *et al.*, "ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases," in *Proceedings of the 2017 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'17)*, ser. CVPR '17. IEEE Computer Society, 2017.
- [17] D. Tzutalin, "LabelImg," 2015. [Online]. Available: <https://github.com/tzutalin/labelImg>
- [18] A. B. Alexey, "YOLO mark," 2018. [Online]. Available: [https://github.com/AlexeyAB/Yolo\\_mark](https://github.com/AlexeyAB/Yolo_mark)
- [19] E. Weill, "Convert datasets," 2017. [Online]. Available: <https://github.com/eweill/convert-datasets>
- [20] P. Simard, D. Steinkraus, and J. C. Platt, "Best practices for convolutional neural networks applied to visual document analysis," in *Proceedings of the 12th International Conference on Document Analysis and Recognition (ICDAR'03)*, I. C. Society, Ed., vol. 2, 2003, pp. 958–964.
- [21] M. D. Bloice, C. Stocker, and A. Holzinger, "Augmentor: An Image Augmentation Library for Machine Learning," *CoRR*, vol. abs/1708.04680, 2017. [Online]. Available: <http://arxiv.org/abs/1708.04680>
- [22] A. Jung, "Imgaug: a library for image augmentation in machine learning experiments," 2017. [Online]. Available: <https://github.com/aleju/imgaug>
- [23] J. Heras *et al.*, "CLoDSA: an open-source image augmentation library for object classification, localization, detection and semantic segmentation," 2018. [Online]. Available: <https://github.com/joheras/CLoDSA>
- [24] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?" in *Advances in Neural Information*



- Processing Systems 27*, Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, and K. Q. Weinberger, Eds. Curran Associates, Inc., 2014, pp. 3320–3328.
- [25] W. S. Sarle, “Stopped training and other remedies for overfitting,” in *Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics*, 1995, pp. 352–360.
- [26] T. Kluyver *et al.*, “Jupyter notebooks — a publishing format for reproducible computational workflows,” in *Proceedings of the 20th International Conference on Electronic Publishing*. IOS Press, 2016, pp. 87–90.
- [27] R. J. Brunner and E. J. Kim, “Teaching data science,” *Procedia Computer Science*, vol. 80, pp. 1947 – 1956, 2016.
- [28] K. J. O’hara, D. S. Blank, and J. Marshall, “Computational notebooks for ai education,” in *Proceedings of the Twenty-Eighth International Florida Artificial Intelligence Research Society Conference (FLAIRS 2015)*, 2015, pp. 263–268.
- [29] F. Pedregosa *et al.*, “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [30] A. Kaebler and G. Bradski, *Learning OpenCV 3*. O’Reilly Media, 2015.
- [31] B. R. Buttery *et al.*, “Stomatal numbers of soybean and response to water stress,” *Plant and Soil*, vol. 149, no. 2, pp. 283–288, 1993.
- [32] P. Giorio, G. Sorrentino, and R. D’Andria, “Stomatal behaviour, leaf water status and photosynthetic response in field-grown olive trees under water deficit,” *Environmental and Experimental Botany*, vol. 42, no. 2, pp. 95–104, 1999.
- [33] S. Violet-Chabrand and O. Brendel, “Automatic measurement of stomatal density from microphotographs,” *Trees - Structure and Function*, vol. 28, no. 6, pp. 1859–1865, 2014.
- [34] S. Liu *et al.*, “A fast method to measure stomatal aperture by mser on smart mobile phone,” in *Proceedings of the Imaging and applied optics congress*, 2016, pp. 3–5.
- [35] H. Jayakody *et al.*, “Microscope image based fully automated stomata detection and pore measurement method for grapevines,” *Plant Methods*, vol. 13, no. 94, 2017.
- [36] J. Gao *et al.*, “PANDA: Facilitating Usable AI Development,” *CoRR*, vol. abs/1804.09997, 2018. [Online]. Available: <http://arxiv.org/abs/1804.09997>
- [37] Google, “Automl vision,” 2018. [Online]. Available: <https://cloud.google.com/automl/>



# Análisis del impacto de datos desbalanceados en el rendimiento predictivo de redes neuronales convolucionales

Francisco J. Pulgar, Antonio J. Rivera, Francisco Charte, María J. del Jesus  
*Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence (DaSCI)*  
*Departamento de Informática*  
*Universidad de Jaén*  
Jaén, España  
{fpulgar, fcharte, arivera, mjjesus}@ujaen.es

**Abstract**—En los últimos años han surgido nuevas propuestas basadas en Deep Learning para afrontar la tarea de clasificación. Estas propuestas han obtenido buenos resultados en algunos campos, por ejemplo, en reconocimiento de imágenes. Sin embargo, existen factores que deben ser analizados para valorar su influencia en los resultados obtenidos con estos nuevos modelos. En este trabajo se analiza la clasificación de datos desbalanceados con redes neuronales convolucionales (Convolutional Neural Networks-CNNs). Para hacerlo, se han llevado a cabo una serie de tests donde se reconocen imágenes mediante CNNs. Así mismo, se utilizan conjuntos de datos con diferente grado de desbalanceo. Los resultados demuestran que el desequilibrio afecta negativamente al rendimiento predictivo.

**Index Terms**—Deep Learning, redes neuronales convolucionales, reconocimiento de imágenes, dataset desbalanceado.

## I. INTRODUCCIÓN

La tarea de clasificación es una de las más estudiadas dentro del aprendizaje automático, fundamentalmente debido a su gran aplicación para resolver problemas reales. El objetivo principal de esta tarea es obtener un modelo que permita clasificar correctamente nuevos ejemplos, a partir de una serie de instancias previamente etiquetadas [1].

En los últimos años se ha producido un auge en el uso de técnicas basadas en Deep Learning (DL) para afrontar el problema de clasificación. Esto se debe fundamentalmente a dos razones: la gran cantidad de datos disponible y el incremento en la capacidad de procesamiento. Estas técnicas han mostrado muy buenos resultados en clasificación, especialmente en campos como el reconocimiento de imágenes y audio [2], [3].

Uno de los modelos que han obtenido mejores resultados en el reconocimiento de imágenes son las redes neuronales convolucionales (CNNs) [4]. Debido a la naturaleza de la convolución, estas redes se adaptan a la forma en la que se distribuyen los datos de entrada en el caso de las imágenes.

A pesar de los buenos resultados obtenidos con CNNs, son modelos relativamente recientes y existen factores que deben ser estudiados. Uno de ellos es la necesidad de analizar cómo el desbalanceo de los datos afecta al rendimiento predictivo obtenido mediante CNNs. Muchos conjuntos de datos reales

contienen algún grado de desbalanceo, de ahí la importancia de estudiar este factor.

Por ello, este estudio se centra en analizar los efectos del desbalanceo de los datos en la clasificación, usando CNNs, de imágenes reales correspondientes a señales de tráfico. En este sentido, se establece la hipótesis de que el rendimiento predictivo se verá afectado negativamente a medida que aumenta el desbalanceo de los datos. La razón que lleva a plantear esta hipótesis es una cuestión de similitud con otras técnicas tradicionales, si el desbalanceo influye negativamente en la clasificación de las redes neuronales tradicionales, podría influir de forma similar a la realizada mediante CNNs. Así mismo, la naturaleza de las CNNs puede verse influenciada por el desequilibrio, ya que el ajuste de los parámetros puede depender del número de ejemplos de cada una de las clases.

El artículo está estructurado de la siguiente forma: La Sección II explica cómo afecta el desbalanceo de los datos a la tarea de clasificación. En la Sección III se introduce el concepto de DL y de CNNs. La Sección IV se pretende verificar la hipótesis establecida, para ello se lleva a cabo una experimentación donde se clasifican conjuntos de imágenes reales mediante CNNs y con diferente grado de desbalanceo. Finalmente, en la Sección V se indican las conclusiones alcanzadas.

## II. EL PROBLEMA DE DESBALANCEO EN CLASIFICACIÓN

La clasificación es una tarea de predicción que, normalmente, utiliza métodos de aprendizaje supervisados [5]. Su propósito es aprender, basándose en datos previos etiquetados, patrones que permitan predecir la clase a asignar a futuros ejemplos que no estén etiquetados. En la clasificación tradicional, los conjuntos de datos están compuestos por una serie de atributos de entrada y un único valor de salida, la clase o etiqueta.

En muchas situaciones reales donde se aplica la clasificación, existen diferencias significativas en el número de elementos correspondientes a las diferentes clases, por tanto, la probabilidad de que un ejemplo pertenezca a cada una de las clases es distinta. Esta situación se conoce como el problema

de desbalanceo [6]–[8]. En muchos casos, la clase minoritaria es la más interesante a la hora de clasificar y tiene un gran coste en caso de no hacerlo correctamente.

Muchos algoritmos de clasificación obtienen buenos resultados cuando trabajan con elementos de la clase mayoritaria, pero los resultados con instancias de la clase minoritaria son erróneos frecuentemente. Esto implica que estos algoritmos, que obtienen buenos resultados con conjuntos de datos balanceados, no obtengan buen rendimiento con datos desbalanceados. Existen diferentes razones para ello:

- Muchas medidas de rendimiento usadas para guiar el proceso de entrenamiento penalizan a las clases minoritarias.
- Las reglas que predicen las clases minoritarias están muy especializadas y su cobertura es muy baja, por ello, a menudo son descartadas en favor de reglas más generales, es decir, aquellas que predicen a las clases mayoritarias.
- El tratamiento del ruido puede afectar a la clasificación de las clases minoritarias, ya que estas clases pueden ser identificadas como ruido y descartadas erróneamente o el ruido existente puede afectar en gran medida a la clasificación de las clases minoritarias.

El principal obstáculo es que los algoritmos de clasificación se entrenan con un mayor número de instancias de la clase mayoritaria y cometen más errores cuando intenta clasificar ejemplos de la clase minoritaria. Para afrontar el problema han surgido muchas propuestas que pueden agruparse en [9]:

- **Muestreo de datos:** esta propuesta se basa en modificar el conjunto de entrenamiento proporcionado al algoritmo de clasificación. El objetivo es obtener datos de entrenamiento cuyas clases tengan una distribución más balanceada. En este caso, el algoritmo de clasificación no sufre ninguna modificación [10].
- **Adaptación de algoritmos:** el objetivo perseguido por este tipo de solución es adaptar los algoritmos tradicionales de clasificación para trabajar con datos desbalanceados [11]. En estos casos los datos no son modificados, es el algoritmo el que debe adaptarse.
- **Aprendizaje sensible al coste:** este tipo de solución puede incorporar modificaciones a nivel de datos y de algoritmo. Se basa en incluir penalizaciones más fuertes a los errores cometidos con la clase minoritaria que a los que se producen al clasificar la clase mayoritaria [12].

Al abordar problemas con datos desbalanceados, deben tenerse en cuenta otros factores que pueden tener gran influencia en los resultados obtenidos, por ejemplo, el solapamiento entre clases [13] o el ruido existente en los datos [14].

### III. DEEP LEARNING

La necesidad de extraer información de más alto nivel de los datos analizados a través de métodos de aprendizaje ha hecho que emerjan nuevas áreas de estudio, en concreto DL [15]. Los modelos de DL están basados en una arquitectura profunda (multi-capa) cuyo objetivo es mapear las relaciones entre las características de los datos y los resultados esperados [16]. Este tipo de métodos aportan las siguientes ventajas:

- Los modelos DL incorporan mecanismos para generar nuevas características por sí mismos, sin necesidad de realizar esto en fases externas.
- Las técnicas DL mejoran el rendimiento en cuanto a tiempo de cómputo, al realizar algunas de las tareas más costosas, como la generación de nuevas características.
- Los modelos basados en DL obtienen buenos resultados al afrontar problemas en ciertos campos como reconocimiento de imágenes o sonido, mejorando a técnicas tradicionales [2], [3].

Debido a los buenos resultados obtenidos usando propuestas basadas en DL, se han ido desarrollando diferentes arquitecturas, por ejemplo, CNNs [17] o redes neuronales recurrentes [18]. Estas arquitecturas han sido diseñadas para múltiples campos de aplicación, mostrando una gran eficiencia en el reconocimiento de imágenes. En la Sección III-A, se profundiza sobre el concepto de CNN, modelo que será usado en la experimentación asociada a este estudio.

#### A. Redes Neuronales Convolucionales

Las CNNs son un tipo de red neuronal profunda basada en la forma en la que los animales visualizan e identifican los objetos. Estas redes han mostrado un funcionamiento muy eficiente en ciertos campos de aplicación como en clasificación y reconocimiento de imágenes.

Las CNNs se basan en la idea de la correlación espacial mediante la aplicación de una serie de patrones de conectividad local entre neuronas de capas adyacentes [4], [19]–[21]. Esto implica que, al contrario que otras redes neuronales tradicionales donde cada neurona se conecta con todas las neuronas de las capas anteriores, en las CNNs cada neurona se conecta únicamente a una región concreta de la capa anterior. Otra diferencia fundamental es que las neuronas de las CNNs están distribuidas en tres dimensiones, mientras que las redes tradicionales sólo ocupan dos dimensiones. La Figura 1 muestra la diferencia entre ambos tipos de redes.

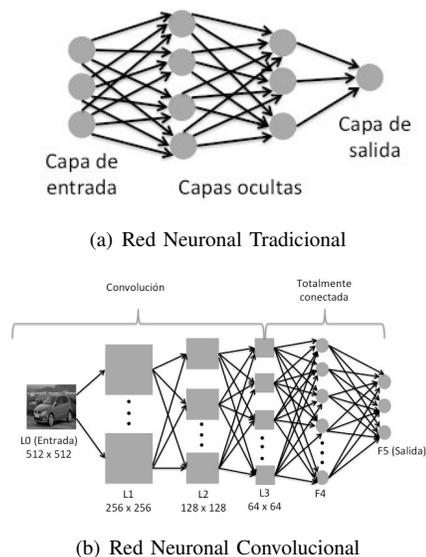


Fig. 1. Diferencias entre redes neuronales tradicionales y CNNs.



La arquitectura de una CNN está basada en una secuencia de capas, cada una de ellas transforma el volumen de entrada mediante la utilización de una función concreta. Hay tres tipos: capa de convolución, de *pooling* y totalmente conectada. Los tipos de capas indicados anteriormente se usan para formar una CNN compleja, para ello, capas de diferentes tipos se enlazan para formar la arquitectura del modelo que se quiera construir [4], [17], [20], [21].

#### IV. EXPERIMENTACIÓN

Una vez expuestos los principales conceptos teóricos necesarios para establecer las bases de este trabajo, se presenta la hipótesis que se pretende verificar y la experimentación que se ha desarrollado para hacerlo.

Durante esta fase se pretende demostrar si un excesivo desequilibrio entre las instancias de las diferentes clases que forman el conjunto de datos afecta al rendimiento predictivo obtenido utilizando CNNs.

Existen diferentes estudios [9]–[12] que muestran que esta propiedad de los datos afecta a determinados modelos de clasificación y proponen soluciones para reducir los efectos al trabajar con datos que presenten desequilibrio. Sin embargo, debido a que las técnicas basadas en CNNs son relativamente recientes, apenas existen estudios que analicen la influencia de los datos desbalanceados en este tipo de modelos.

En este trabajo, se asume la idea de que los datos con desequilibrio entre las clases afectan a la clasificación mediante CNNs. Este hecho lleva a proponer la hipótesis inicial del trabajo: los resultados obtenidos mediante CNNs utilizando datos desbalanceados reducen el rendimiento predictivo de las mismas.

Por tanto, el objetivo de este estudio es analizar si los datos desbalanceados influyen negativamente en la clasificación de imágenes utilizando CNNs. Para hacerlo, se realizan una serie de test usando datos con diferente nivel de desbalanceo (ratio de desbalanceo-IR). Estos datos corresponden a imágenes de tráfico reales [22], siendo el objetivo asociar cada imagen de entrada a la señal correspondiente. El modelo utilizado para realizar la clasificación será una CNN, cuya red usada tendrá la misma arquitectura en todos los experimentos llevados a cabo. Así mismo, debe tenerse en cuenta que no se va a utilizar ningún mecanismo para reducir los efectos del desbalanceo, ya que el objetivo es analizar cómo afectan a estos modelos.

##### A. Framework experimental

Para desarrollar el experimento se ha utilizado un dataset de señales de tráfico [22] con un total de 11 910 imágenes pertenecientes a 43 tipos de señales o clases diferentes. En primer lugar, es necesario realizar un pre-procesamiento de las imágenes. Esta fase tiene dos objetivos fundamentales: por un lado, recortar la imagen para seleccionar solo la parte correspondiente a la señal de tráfico (Figura 2); y, por otro lado, escalar las imágenes para hacer que todas ellas tengan la misma dimensión. En este sentido, se ha decidido escalar las imágenes a un tamaño de 32x32, ya que es el usado en otros estudios similares [19].

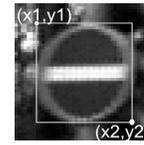


Fig. 2. Ejemplo de imagen recortada (fuente: <http://benchmark.ini.rub.de>).

Una vez que todas las imágenes del conjunto de datos han sido pre-procesadas, se seleccionan las correspondientes a 10 clases con el objetivo de acentuar el desbalanceo entre los datos. Las clases seleccionadas serán las 5 con más ejemplos y las 5 con menos ejemplos. De esta forma, se obtiene un subconjunto de datos a partir del conjunto completo original.

Una aspecto importante cuando se trabaja con datos desbalanceados es el IR. Esta medida es definida como el ratio entre el número de ejemplos de la clase mayoritaria y el de la clase minoritaria [23], [24].

Otro aspecto a tener en cuenta es que el número de imágenes usadas en cada experimento será el mismo, únicamente cambiará el IR del conjunto de datos. Esto es importante, ya que si el número de ejemplos varía de forma significativa puede afectar a los resultados obtenidos, ocultando así los efectos del desequilibrio de los datos. Por tanto, se han seleccionado 2 700 imágenes para cada ejecución. La razón por la que se selecciona este número viene dada por la cantidad de imágenes de las clases minoritarias en el dataset original. Este conjunto contiene unas 270 imágenes de las clases minoritarias y unas 2 700 de las mayoritarias. Al balancear el conjunto de datos, se seleccionan 270 imágenes de cada clase, por lo que el número total de instancias es 2 700, que se mantiene constante durante todas las ejecuciones, a pesar de cambiar el IR.

Finalmente, se deben indicar que las métricas de evaluación usadas para evaluar el rendimiento predictivo de la CNN en cada caso serán: Tasa de Error, *Precision* y *Recall*.

##### B. Arquitectura de la CNN

La arquitectura de la CNN usada para clasificar debe ser la misma en todos los casos, a pesar de que el conjunto de imágenes variará en cada uno de ellos. Esto es necesario para evaluar los efectos del desequilibrio en los datos. Esta CNN tiene una arquitectura cuya secuencia de capas es la siguiente:

- **Capa convolucional 1:** 32 filtros son aplicados sobre la imagen original. Tienen un tamaño de 5x5. Esto produce 32 mapas de características.
- **Capa pooling 1:** Los 32 mapas anteriores se reducen usando la función máximo con una ventana de pooling de tamaño 2 y un paso 2.
- **Capa convolucional 2:** Esta capa aplica 64 filtros con un tamaño de 5x5 sobre la salida de la capa anterior y genera un nuevo conjunto de mapas de características.
- **Capa pooling 2:** Se reduce la dimensionalidad de los mapas de características anteriores. Se utiliza la función máximo con una ventana de tamaño 2 y un paso 2.
- **Capa completamente conectada:** En esta capa todos los elementos de la fase anterior son combinados y

usados para realizar la clasificación. Esta capa tiene tantos elementos como clases tenga el problema.

Durante el proceso de entrenamiento, se usa la entropía cruzada para evaluar la red y, posteriormente, la propagación hacia atrás para modificar los pesos de la red. La configuración elegida para la red es la usada por defecto en el software utilizado, TensorFlow<sup>1</sup>, considerando el tamaño de las imágenes y los diferentes valores de salida que puede tener el problema.

### C. Análisis de resultados

La experimentación llevada a cabo consiste en diferentes ejecuciones en las que se clasifican imágenes reales mediante una CNN, cada una de las cuales tiene diferente IR. En concreto, se han realizado cuatro experimentos con IR 1/10, 1/5, 1/3 y 1/1.

Como se ha descrito en la Sección IV-A, el conjunto de datos seleccionado tiene un total de 11 910 imágenes. Sin embargo, se ha justificado el hecho de seleccionar únicamente 2 700 imágenes en cada uno de los experimentos, con el objetivo de que todas las ejecuciones tengan el mismo número de instancias. Por ello, el primer paso consiste en reducir el número de imágenes de cada clase de forma proporcional y aleatoria, para obtener el número establecido sin afectar a la tasa de desbalanceo. Así, los distintos conjuntos de datos presentan la distribución de ejemplos que puede verse en la Tabla I para cada clase.

Tabla I  
INSTANCIAS DE ENTRENAMIENTO Y TEST POR EXPERIMENTACIÓN.

Clase	IR 1/10		IR 1/5		IR 1/3		IR 1/1	
	Train	Test	Train	Test	Train	Test	Train	Test
1	36	11	66	20	98	31	203	67
2	351	115	320	106	288	95	203	67
3	392	130	361	118	325	106	203	67
4	365	121	334	111	301	100	203	67
5	376	125	345	115	311	103	203	67
6	36	11	65	21	97	32	203	67
7	39	13	72	24	108	36	203	67
8	36	11	65	21	97	32	203	67
9	360	120	330	110	297	99	203	67
10	39	13	72	24	108	36	203	67
Total	2030	670	2030	670	2030	670	2030	670

La Tabla I muestra el número de ejemplos de cada una de las clases para los conjuntos de datos de cada ejecución. En ella, se puede ver que todas tienen un total de 2 700 imágenes de las que 2 030 serán usadas para entrenar la red y 670 para evaluar el modelo. Sin embargo, se puede apreciar como el ratio entre las instancias de las clases mayoritarias y minoritarias es diferente. A continuación, se exponen los resultados obtenidos en dichos experimentos.

#### 1) Resultados con IR 1/10:

El primer experimento de clasificación de imágenes utilizando CNN llevado a cabo comienza con un conjunto de datos con un gran nivel de desbalanceo entre clases. La Tabla I muestra el número de instancias de cada una de ellas. Así mismo, se puede ver cómo, en este primer experimento, existe un IR de aproximadamente 1/10 entre las clases minoritarias y mayoritarias. Una vez establecido el conjunto de datos, se

<sup>1</sup><https://www.tensorflow.org/>

utiliza una CNN para realizar la clasificación, obteniendo los resultados presentados en las Tablas II y III.

Tabla II  
NÚMERO DE INSTANCIAS TOTAL Y ERRORES EN TEST POR EXPERIMENTACIÓN.

Clase	IR 1/10		IR 1/5		IR 1/3		IR 1/1	
	Test	Error	Test	Error	Test	Error	Test	Error
1	11	4	20	4	31	2	67	1
2	115	1	106	3	95	2	67	0
3	130	1	118	2	106	2	67	3
4	121	2	111	0	100	2	67	0
5	125	0	115	2	103	0	67	0
6	11	4	21	2	32	2	67	0
7	13	2	24	0	36	0	67	0
8	11	4	21	1	32	0	67	0
9	120	1	110	1	99	1	67	1
10	13	3	24	0	36	0	67	3
Total	670	22	670	15	670	11	670	8

La Tabla II muestra el número de ejemplos de test por clase y el número de errores del modelo al clasificar dichos ejemplos. Además, en la Tabla III se puede ver las métricas Tasa de Error, *Precision* y *Recall* por clase. Ambas tablas presentan los resultados para los 4 experimentos realizados.

En el primero experimento con IR 1/10, los resultados obtenidos muestran que la Tasa de Error por clase tiene un valor global de 0.033, en concreto, de las 670 imágenes de test son clasificadas erróneamente 22. Así mismo, el valor medio de *Precision* es de 0.963 y el de *Recall* 0.848. Estos resultados servirán de base para determinar si las ejecuciones realizadas con menor grado de desbalanceo tienen mejor rendimiento.

#### 2) Resultados con IR 1/5:

El siguiente paso es reducir el IR a 1/5. Para hacerlo, en primer lugar se parte del dataset original con 11 910 imágenes y, posteriormente, se realiza una selección aleatoria del 50% de ejemplos de las clases mayoritarias. De esta forma obtenemos un subconjunto con 6 510 imágenes. Una vez hecho esto, se seleccionan 2 700 para que todos los experimentos tengan el mismo número de instancias.

En la Tabla I puede verse el número de ejemplos por clase para este experimento y puede verificarse que el IR es de 1/5. Los resultados obtenidos al clasificar con la CNN esta nueva distribución de ejemplos se muestra en las Tablas II y III.

Estos resultados con un IR 1/5 muestran cómo disminuye la Tasa de Error con respecto a la ejecución anterior. La Tasa de Error obtenida es 0.022, ya que 15 imágenes del total de 670 de test han sido clasificadas erróneamente. Además, los resultados muestran que tanto *Precision* como *Recall* aumentan respecto al experimento previo. El valor medio de *Precision* obtenido es de 0.984 y el de *Recall* es 0.958. Los resultados refuerzan la hipótesis inicial, por lo que se continúa reduciendo el IR.

#### 3) Resultados con IR 1/3:

Para continuar verificando la hipótesis, se reduce el IR a 1/3. Para ello, a partir del dataset de partida con 11 910 imágenes, se selecciona de forma aleatoria el 30% de los ejemplos de las clases mayoritarias, obteniendo un subconjunto con 4 350 imágenes. Posteriormente, se seleccionan 2 700 para que todas las ejecuciones tengan el mismo tamaño.



Tabla III  
RESULTADOS PARA CONJUNTO DE TEST.

Clase	IR 1/10			IR 1/5			IR 1/3			IR 1/1		
	Error	Precision	Recall									
1	0.364	<b>1.000</b>	0.636	0.200	<b>1.000</b>	0.800	0.065	<b>1.000</b>	0.935	<b>0.015</b>	0.985	<b>0.985</b>
2	0.009	0.966	0.991	0.028	0.954	0.972	0.021	0.989	0.979	<b>0.000</b>	<b>1.000</b>	<b>1.000</b>
3	<b>0.008</b>	0.963	<b>0.992</b>	0.017	0.951	0.983	0.019	0.990	0.981	0.045	<b>1.000</b>	0.955
4	0.017	0.983	0.983	<b>0.000</b>	<b>1.000</b>	<b>1.000</b>	0.020	0.990	0.980	<b>0.000</b>	0.985	<b>1.000</b>
5	<b>0.000</b>	0.977	<b>1.000</b>	0.017	0.983	0.983	<b>0.000</b>	0.956	<b>1.000</b>	<b>0.000</b>	<b>0.985</b>	<b>1.000</b>
6	0.364	0.875	0.636	0.095	<b>1.000</b>	0.905	0.062	0.968	0.937	<b>0.000</b>	0.985	<b>1.000</b>
7	0.154	0.917	0.846	<b>0.000</b>	0.960	<b>1.000</b>	<b>0.000</b>	0.947	<b>1.000</b>	<b>0.000</b>	<b>1.000</b>	<b>1.000</b>
8	0.364	<b>1.000</b>	0.636	0.048	<b>1.000</b>	0.952	<b>0.000</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	0.985	<b>1.000</b>
9	<b>0.008</b>	0.952	<b>0.992</b>	0.009	0.991	0.991	0.010	<b>1.000</b>	0.990	0.015	0.956	0.985
10	0.231	<b>1.000</b>	0.769	<b>0.000</b>	<b>1.000</b>	<b>1.000</b>	<b>0.000</b>	<b>1.000</b>	<b>1.000</b>	0.045	<b>1.000</b>	0.955
Media	0.033	0.963	0.848	0.022	0.984	0.958	0.016	0.984	0.980	<b>0.012</b>	<b>0.988</b>	<b>0.988</b>

En la Tabla I, se verifica que la distribución de ejemplos por clase de la tercera experimentación tiene un IR de 1/3, ya que se ha llevado a cabo una reducción mayor de las instancias de la clase mayoritaria. Los resultados obtenidos con esta nueva distribución pueden verse en las Tablas II y III.

Observando los resultados para este experimento con un IR de 1/3, se puede ver que la tendencia vista en la sección previa continúa, ya que mejora el rendimiento. En este caso, la tasa de Error global obtenida es de 0.016, en concreto, se clasifican mal 11 imágenes del total de 670 del conjunto de test. Así mismo, el valor medio de *Precision* es de 0.984 y el de *Recall* es 0.980. De esta forma, se verifica la tendencia general que confirma que, a medida que decrece el IR, los resultados de clasificación mediante CNNs mejoran. Este hecho vuelve a confirmar la hipótesis inicial y, por ello, se pasa a realizar el último experimento con el dataset completamente balanceado.

#### 4) Resultados con IR 1/1:

El objetivo de este último test es, como se ha descrito anteriormente, verificar la mejora de los resultados obtenidos al clasificar con CNN utilizando un dataset balanceado (IR 1/1). Por tanto, el primer paso es balancear el conjunto de datos inicial de 11 910 imágenes. Para hacerlo, se selecciona la clase con menos ejemplos y se eliminan elementos aleatoriamente del resto de clases hasta que tengan el mismo número de instancias. De esta forma, se obtiene un subconjunto de imágenes para llevar a cabo la experimentación con 2 700, cuya distribución puede verse en la Tabla I.

Las Tablas II y III muestran los resultados obtenidos en clasificación usando una CNN y un conjunto de datos balanceado. La Tasa de Error es de 0.012, solo se han clasificado mal 8 imágenes del total de 670 de test, el valor de *Precision* es 0.988 y el de *Recall* 0.988. Estos resultados vuelven a mejorar los obtenidos en las experimentaciones previas.

Las evidencias mostradas por las distintas experimentaciones confirman la hipótesis inicial: a medida que el conjunto de datos está más balanceado, los resultados de la clasificación realizada con CNNs mejoran.

#### 5) Discusión de Resultados:

En las Subsecciones previas, se ha confirmado la hipótesis

inicial de este artículo. A continuación se muestra una representación visual de los resultados obtenidos en las Figuras 3 y 4, así mismo, se realiza una discusión de los mismos.

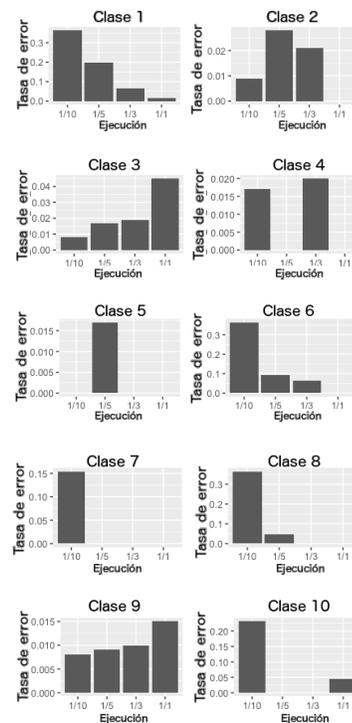


Fig. 3. Tasa de Error por clase y experimento.

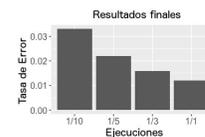


Fig. 4. Tasa media de Error por experimento.

Por un lado, la Figura 3 muestra el Error obtenido por clase para cada experimento, puede verse que en todos los casos, exceptuando las clases 3 y 9, los resultados obtenidos con el conjunto balanceado son los mejores. Por otro lado, la Figura 4 muestra el Error medio para cada experimento, se observa que se obtiene mejor rendimiento a medida que decrece el IR.

Los análisis generales muestran que la reducción del grado de desbalanceo produce una mejora en el rendimiento cuando se clasifica con CNN, lo que confirma la hipótesis inicial. Realizando un estudio por clase, se observa que los mejores resultados se obtienen con el dataset balanceado, excepto en las clases 3 y 9. En estos casos los mejores resultados se obtienen con el conjunto de datos desbalanceado. El motivo puede deberse a que son clases mayoritarias, por lo que al balancear el dataset el número de imágenes de estas clases es menor que en el conjunto de datos desbalanceado, factor que puede afectar al rendimiento predictivo.

Una vez realizado el análisis previo, se concluye que uno de los aspectos que más podría afectar al rendimiento es el cálculo de los pesos de la última capa de la red convolucional. Esta capa completamente conectada determina la clase en una última fase supervisada, y los pesos obtenidos podrían priorizar las clases mayoritarias con respecto a las minoritarias.

Otra característica de la CNN que podría influir es el cálculo de los pesos correspondientes a los diferentes filtros en las capas convolucionales. Estos se mueven a lo largo del espacio de entrada, modificando los pesos durante el proceso, de modo que se podrían adaptar excesivamente a las clases mayoritarias cuando hay un mayor desequilibrio. Estas conclusiones abren nuevas vías de estudio, ya que son necesarios análisis más detallados para verificar si se cumplen o no.

#### V. CONCLUSIONES

Uno de los principales problemas cuando se afronta la tarea de clasificación con datos reales es que, en muchos casos, no están balanceados, lo que influye negativamente en el rendimiento predictivo de gran cantidad de modelos. En este trabajo, se verifica si este problema de desequilibrio afecta también a la clasificación realizada con CNNs.

Las ejecuciones realizadas han confirmado la hipótesis inicial: a medida que el desbalanceo en los datos es minimizado, los resultados obtenidos a través de la CNN mejoran. Esto implica que debe tenerse en cuenta la distribución de los datos cuando se usan este tipo de técnicas, ya que un excesivo desequilibrio puede afectar negativamente.

Los resultados derivados de este estudio abren nuevas vías de trabajo. Una primera aproximación para afrontar el problema asociado a clasificar datos desbalanceados con CNNs es la aplicación de métodos clásicos: técnicas de muestreo, métodos de aprendizaje sensibles al coste o ensembles, estas técnicas tienen como objetivo reducir los efectos del desequilibrio de los datos. Así mismo, existe la posibilidad de crear nuevos modelos que combinen técnicas tradicionales que afronten el problema de desbalanceo con CNNs, generando algoritmos híbridos que tengan en cuenta este factor.

Este trabajo es una primera aproximación al problema utilizando un conjunto de datos particular y una técnica concreta, por lo que este estudio debe ser ampliado en trabajos futuros para establecer una conclusiones sólidas.

#### AGRADECIMIENTOS

Este trabajo de F. Pulgar ha sido financiado por el Ministerio de España de Educación bajo el Programa Nacional FPU (Ref.

FPU16/00324). Este trabajo ha sido parcialmente financiado por el Ministerio de España de Ciencia y Tecnología bajo el proyecto TIN2015-68454-R.

#### REFERENCIAS

- [1] R. Duda, P. Hart, D. Stork, *Pattern Classification*, 2nd edition, John Wiley, 2000.
- [2] D. Ciresan, U. Meier, Multi-column Deep Neural Networks for Image Classification, Technical Report No. IDSIA-04-12, 2012.
- [3] R. McMillan, How Skype Used AI to Build Its Amazing New Language Translator, *Wire*, 2014.
- [4] Y. LeCun, K. Kavukcuoglu, C. Farabet, Convolutional networks and applications in vision, in *Circuits and Systems (ISCAS)*, in Proceedings of 2010 IEEE International Symposium on, p. 253-256, 2010.
- [5] S. Kotsiantis, Supervised machine learning: A review of classification techniques, *Proceedings of the 2007 conference on Emerging Artificial Intelligence Applications in Computer Engineering*, p. 3-24, 2007.
- [6] N.V. Chawla, N. Japkowicz, A. Kotcz, Editorial: special issue on learning from imbalanced data sets, *SIGKDD Explorations*, 6 (1), p. 1-6, 2004.
- [7] H. He, E.A. García, Learning from imbalanced data, *IEEE Transactions on Knowledge and Data Engineering*, 21 (9), p. 1263-1284, 2009.
- [8] Y. Sun, A.K.C. Wong, M.S. Kamel, Classification of imbalanced data: a review, *International Journal of Pattern Recognition and Artificial Intelligence*, 23 (4), p. 687-719, 2009.
- [9] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, F. Herrera, A review on ensembles for class imbalance problem: bagging, boosting and hybrid based approaches, *IEEE Transactions on Systems, Man, and Cybernetics*, 42 (4), p. 463-484, 2012.
- [10] G.E.A.P.A. Batista, R.C. Prati, M.C. Monard, A study of the behaviour of several methods for balancing machine learning training data, *SIGKDD Explorations*, 6 (1), p. 20-29, 2004.
- [11] B. Zadrozny, Learning and making decisions when costs and probabilities are both unknown, *Proceedings of the 7th International Conference on Knowledge Discovery and Data Mining*, p. 204-213, 2001.
- [12] B. Zadrozny, J. Langford, N. Abe, Cost-sensitive learning by cost-proportionate example weighting, in *Proceedings of the 3rd IEEE International Conference on Data Mining (ICDM'03)*, p. 435-442, 2003.
- [13] Prati, R. C., Batista, G. E., Monard, M. C., Class imbalances versus class overlapping: an analysis of a learning system behavior, in *Mexican international conference on artificial intelligence*, p. 312-321, 2004.
- [14] Frénay, B., Verleysen, M., Classification in the presence of label noise: a survey, *IEEE transactions on neural networks and learning systems*, 25(5), p. 845-869, 2014.
- [15] Y. Bengio, A. Courville, P. Vincent, Representation Learning: A Review and New Perspectives. *Pattern Analysis and Machine Intelligence*, IEE Transactions, 3 (8), p. 1798-1828, 2013.
- [16] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, 2016.
- [17] Y. LeCun, Y. Bengio, Convolutional networks for images, speech, and time-series, M. A. Arbib, *The Handbook of Brain Theory and Neural Networks*, 1995.
- [18] H. Sak, A. Senior, F. Beaufays, Long short-term memory recurrent neural network architectures for large scale acoustic modeling, *Proc. Interspeech*, p. 338-342, 2013.
- [19] P. Sermanet, Y. LeCun, Traffic sign recognition with multi-scale convolutional networks, in *Proceedings of International Joint Conference on Neural Networks*, 2011.
- [20] Krizhevsky, A., Sutskever, I., Hinton, G. E., Imagenet classification with deep convolutional neural networks, in *Advances in neural information processing systems*, p. 1097-1105, 2012.
- [21] Jin, K. H., McCann, M. T., Froustey, E., Unser, M., Deep convolutional neural network for inverse problems in imaging, *IEEE Transactions on Image Processing*, 26(9), p. 4509-4522, 2017.
- [22] J. Stallkamp, M. Schlipsing, J. Salmen, and C. Igel, Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition, *Neural Networks*, vol. 32, p. 323-332, 2012.
- [23] V. García, J.S. Sánchez, R.A. Mollineda, On the effectiveness of preprocessing methods when dealing with different levels of class imbalance, *Knowledge Based Systems*, 25 (1), p. 13-21, 2012.
- [24] A. Orriols-Puig, E. Bernadó-Mansilla, Evolutionary rule-based systems for imbalanced datasets, *Soft Computing*, 13 (3), p. 213-225, 2009.



# Comparación de marcos de trabajo de Aprendizaje Profundo para la detección de objetos

Jesús Benito-Picazo, Karl Thurnhofer-Hemsi, Miguel A. Molina-Cabello, Enrique Domínguez

*Departamento de Lenguajes y Ciencias de la Computación*

*Universidad de Málaga*

Bulevar Louis Pasteur, 35. 29010 Málaga. España.

{jpicazo, karlkhader, miguelangel, enrique}@lcc.uma.es

**Resumen**—Muchas aplicaciones en visión por computador necesitan de sistemas de detección precisos y eficientes. Esta demanda coincide con el auge de la aplicación de técnicas de aprendizaje profundo en casi todos las áreas del aprendizaje máquina y la visión artificial. Este trabajo presenta un estudio que engloba diferentes sistemas de detección basados en aprendizaje profundo proporcionando una comparativa unificada entre distintos marcos de trabajo con el objetivo de realizar una comparación técnica de las medidas de rendimiento de los métodos estudiados.

**Index Terms**—detección de objetos, aprendizaje profundo, redes neuronales convolucionales

## I. INTRODUCCIÓN

La detección de objetos es una de las tareas de visión por computador más investigadas, donde en la actualidad las Redes Neuronales Convolucionales (CNNs) están mostrando un altísimo rendimiento. Las CNNs están construidas a partir de muchas capas de neuronas intrínsecamente conectadas en un modelo inspirado por la organización jerárquica de la corteza cerebral del ser humano. Las neuronas actúan como una unidad básica en el aprendizaje y extracción de características de la entrada. El rendimiento del aprendizaje y la extracción de características de la entrada se ve mejorada con el aumento de la complejidad de las redes la cual es causada principalmente por la profundidad de las capas de neuronas. Las técnicas de aprendizaje profundo o Deep Learning (DL) en general, y particularmente las CNNs, son capaces de aprender automáticamente, a partir de imágenes genéricas de entrada, datos con múltiples niveles de abstracción debido a la arquitectura profunda que facilita al modelo el proceso de captura y generalización del mecanismo de filtrado realizando operaciones de convolución en el dominio de la imagen. En la literatura se pueden encontrar muchas CNNs de alto rendimiento tales como AlexNet [1], VGG [2], GoogleNet [3], ResNet [4], etc. Algunas como [5], han demostrado superar la precisión del ojo humano en ciertas tareas de reconocimiento de objetos.

A pesar de la popularidad de otros métodos, los métodos basados en DL están superando a otras técnicas tradicionales de visión por computador por un amplio margen en términos de precisión y algunas veces incluso en eficiencia [6]. No obstante, el estado cambiante del DL producido por una falta de trabajos unificadores y revisiones del estado del arte, hacen

la iniciación en este campo tediosa y difícil de mantener actualizada.

El objetivo del presente artículo es realizar un estudio de los marcos de trabajo basados en Deep Learning más prometedores en detección de objetos proporcionando unas medidas de comparación unificadas.

El resto del artículo se organiza como sigue: En la Sección II, se explican las diferentes características de los sistemas de detección y clasificación estudiados, incluidos los conjuntos de datos utilizados para este estudio. La Sección III presenta todas las medidas de rendimiento que han sido utilizadas para realizar los experimentos con los distintos sistemas y los resultados obtenidos de dichos experimentos. La Sección IV se dedicará a la extracción de conclusiones a partir de los resultados obtenidos y a perfilar los siguientes pasos que se darán para mejorar la presente investigación.

## II. METODOLOGÍA

Como ya se comentó en la sección I, el objetivo de este trabajo es realizar una comparación entre diferentes tipos de marcos de trabajo orientados a realizar la detección y localización de objetos basada en redes neuronales profundas. Por tanto, nuestro estudio consistirá en el entrenamiento y prueba de diferentes sistemas fundamentados en modelos de redes neuronales profundas. Como consecuencia, en este trabajo se ha realizado la comparación de cuatro de los citados sistemas: Tensorflow, con su modelo de Faster-RCNN, Pytorch también con su modelo de Faster-RCNN y otros dos sistemas basados en el marco de trabajo de Deep Learning proporcionado por Darknet: uno basado en el modelo YOLO 2.0 (YOLOv2) y otro desarrollado a partir de una combinación del modelo YOLOv2 y el modelo de red neuronal convolucional VGG-16. Dichos modelos serán desglosados con más detalle en las subsecciones II-A, II-B, y II-C, respectivamente. Todos ellos están disponibles para los sistemas operativos Windows, Mac OS X y Linux. La comparación entre los diferentes modelos será llevada a cabo utilizando el conjunto de datos VOC que también será explicado de forma más detallada en la subsección II-D.

### II-A. Tensorflow

Publicado en Febrero de 2011 como una evolución del sistema de aprendizaje máquina *DistBelief* desarrollado por Google

Brain, Tensorflow es un sistema de aprendizaje máquina propietario basado en redes neuronales profundas que es capaz de llevar a cabo operaciones en arrays multidimensionales con soporte para ejecutarse en múltiples GPUs y CPUs utilizando sus extensiones CUDA y SYCL. Oficialmente, Tensorflow presenta APIs para los lenguajes C y Python y, de forma no oficial, presenta soporte para los lenguajes C++, Go y Java. Entre las aplicaciones de este sistema podemos encontrar la localización y clasificación en imágenes y el procesamiento del lenguaje natural o NLP. El sistema que vamos a considerar para la realización de nuestro estudio es la implementación de la red neuronal convolucional Faster-RCNN [7] presentada por Tensorflow. Dada la circunstancia de que las Faster-RCNNs trabajan aplicando un clasificador basado en redes neuronales convolucionales a múltiples regiones de una imagen, en nuestro estudio utilizaremos una Faster-RCNN basada en el bien conocido modelo de red neuronal convolucional VGG-16 en las tareas de detección y localización de objetos.

### II-B. Pytorch

Pytorch es una biblioteca de código abierto orientada al aprendizaje máquina basada en redes neuronales convolucionales que está programada en Python y construida para su integración profunda con este lenguaje de programación. Proporciona tres características principales de alto nivel: cálculo de tensores, aceleración mediante GPUs y redes neuronales convolucionales construidas sobre un sistema de integración automática.

Pytorch proporciona una gran variedad de rutinas para operaciones con tensores para satisfacer las necesidades de computación aprovechando el uso rápido y sencillo del desarrollo basado en el lenguaje Python. También incorpora Redes Neuronales Dinámicas que utilizan una eficiente implementación de una técnica denominada derivación automática en modo inverso, la cual permite a los usuarios cambiar arbitrariamente la forma en que la red se comporta.

Tal y como sucede con el caso del modelo de Tensorflow, hemos seleccionado como nuestro sistema de detección y clasificación la implementación de la Faster-RCNN desarrollada por Pytorch que está basada en el bien conocido modelo de red neuronal convolucional VGG-16.

### II-C. Darknet-YOLO

Darknet es un marco de trabajo desarrollado en lenguaje C++ orientado al diseño, entrenamiento y ejecución de redes neuronales profundas destinadas a la detección y clasificación de objetos en imágenes 2D [8]. Las principales ventajas de este sistema son su simplicidad en términos de uso, tamaño reducido, facilidad de compilación y una documentación en línea clara y concisa. Todas ellas hacen de Darknet-YOLO un sistema fácil de utilizar nada más instalarlo. También es de destacar su capacidad para utilizar el marco de trabajo CUDA de NVIDIA, el cual permite al sistema utilizar la capacidad de cómputo de las GPUs para llevar a cabo tanto procesos de entrenamiento como de validación. Incluido en el marco de trabajo de Darknet, YOLOv2 [9] es un sistema

de detección de objetos que aplica una sola red neuronal a la imagen completa utilizando una sola evaluación de la red para dividirla en regiones, las cuales se utilizarán para predecir las localizaciones de los bounding boxes, en contraposición con otros sistemas tales como las Faster-RCNN, cuyo modo de operación consiste en la aplicación de un modelo de CNN conocido a miles de regiones en la misma imagen. Esta diferencia hace a YOLO un sistema mucho más rápido y computacionalmente ligero que los que llevan otros marcos de trabajo tales como Tensorflow o Pytorch, al mismo tiempo que conserva tasas de precisión aceptables en sus predicciones.

En cuestión de detección y localización de objetos basados en CNNs, Darknet es un sistema interesante porque utiliza un algoritmo diferente del modelo clásico de Faster-RCNN pero consigue resultados similares con una menor carga computacional, lo cual le confiere una mayor velocidad. Por esta razón, en la realización del presente trabajo se han considerado dos modelos distintos de redes neuronales para ser utilizadas con este sistema:

- Uno es YOLOv2 que era el modelo más avanzado de YOLO desarrollado por sus autores, J. Redmon y A. Farhadi, en el momento en que se llevó a cabo el presente estudio.
- El otro es una adaptación de YOLOv2 basada en el modelo de CNN VGG-16 que se ha realizado en este mismo trabajo con el objetivo de poder realizar una comparación con los otros basados en las CNN VGG-16 y que ya se citaron en las subsecciones II-A y II-B del presente documento.

Con el objetivo de que este estudio sea suficientemente fiable y ofrezca unos resultados significativos, es muy importante la selección de un conjunto de datos adecuado que comprenda un conjunto de clases el cual sea lo suficientemente genérico como para representar un buen número de objetos cotidianos, y suficientemente específico como para que ofrezca la posibilidad de extraer conclusiones relacionadas con el rendimiento de cada modelo en las tareas de detección de objetos pertenecientes a clases específicas, y su posibilidad de ser utilizado en determinados entornos. Estas razones han llevado a los autores de este trabajo a seleccionar el popular conjunto de datos VOC2007.

### II-D. Los conjuntos de datos VOC

Estos conjuntos de datos fueron originados en las competiciones *PASCAL Visual Object Classes* [10]. El principal objetivo de dichas competiciones era el de reconocer objetos en escenarios tomados del mundo real. Para ese propósito, fueron seleccionadas veinte categorías diferentes de objetos para las cuales se generaron sendos conjuntos de entrenamiento y validación. El número de clases se incrementó de 10 a 20 respecto al proyecto anterior. Así, se consideraron las siguientes clases: persona, pájaro, gato, vaca, perro, caballo, oveja, aeroplano, bicicleta, barco, autobús, coche, motocicleta, tren, botella, silla, mesa de comedor, maceta, sofá y tv/monitor.

De entre todos los conjuntos VOC, los más utilizados son aquellos que se generaron para las competiciones de los



años 2007 [11] y 2012 [12]. El primero de ellos consta de 9963 imágenes que contienen 24640 objetos etiquetados y el segundo contiene 11530 imágenes con un total de 27450 objetos etiquetados. Los conjuntos se encuentran divididos, estando el 50% dedicado al entrenamiento de los sistemas de clasificación y el 50% restante, a la validación o prueba de dichos sistemas. Por cada uno de los ficheros de imagen, estos conjuntos de datos contienen un fichero que contiene la localización y dimensiones de las regiones rectangulares mínimas así como la clase asociadas a cada uno de los objetos que se encuentran en dicha imagen. Si el objeto no está claro o está visible menos de un 20% del mismo, entonces dicho objeto será descartado.

### III. RESULTADOS EXPERIMENTALES

En la red pueden encontrarse algunas implementaciones similares del modelo de red Faster-RCNN tanto para el marco de trabajo Tensorflow como para Pytorch. Dadas las similitudes de dichas implementaciones, se ha elegido *tf-faster-rcnn* [13] y *faster-rcnn.pytorch* [14] respectivamente. Para el marco de trabajo de Darknet-YOLO solamente está disponible el código original proporcionado por sus creadores.

Como ya se indicó en la Sección II, con el objetivo de realizar una comparación lo más justa posible entre los diferentes modelos y de obtener resultados lo más significativos posibles para nuestro estudio, se han utilizado los conjuntos de datos VOC2007+VOC2012 para el proceso de entrenamiento y el conjunto de datos VOC2007 para realizar las pruebas de las diferentes propuestas.

Todos los experimentos se han llevado a cabo en un ordenador con una CPU modelo Intel(R) Core(TM) i7-5930K de 64 bits con doce núcleos a 3.50GHz, 64GB de RAM y una GPU NVidia GTX Titan X. El sistema operativo base es Linux-Ubuntu 16.04.3 LTS.

Desde un punto de vista cuantitativo, se han seleccionado diferentes medidas bien conocidas para comparar el rendimiento de la detección y la clasificación de las diferentes propuestas estudiadas. Para ser exactos, se ha considerado la exactitud espacial (S) y la F-medida. Estas medidas proporcionan valores en el intervalo [0, 1], donde mayor es mejor, y representan el porcentaje de aciertos del sistema.

También se consideran en este trabajo los verdaderos positivos (True Positives o TP), falsos negativos (False Negatives o FN), falsos positivos (False Positives o FP), la tasa de falsos negativos (False Negative Rate o FNR), Precisión (Precision o PR) y exhaustividad (Recall o RC). Entre todas estas medidas, la exactitud espacial y la F-medida proporcionan una buena evaluación general del rendimiento de un método dado, mientras que FN debe ser considerado contra FP (menor es mejor), y PR contra RC (mayor es mejor).

La definición de cada medida puede ser descrita como sigue:

$$S = \frac{TP}{TP + FN + FP} \quad \text{F-medida} = 2 * \frac{PR * RC}{PR + RC} \quad (1)$$

$$RC = \frac{TP}{TP + FN} \quad PR = \frac{TP}{TP + FP} \quad (2)$$

$$FNR = \frac{FN}{TP + FN}$$

La medida típica para obtener la bondad de un método del tipo Faster-RCNN es la métrica conocida como precisión para la detección de objetos [15]–[17], que utiliza la precisión y la exhaustividad para dibujar la curva precisión-exhaustividad y la precisión media es calculada a partir de las puntuaciones de precisión media para cada clase de objeto.

En este trabajo, la detección y la clasificación son distinguidas y otras evaluaciones han sido consideradas. En este caso, hemos considerado la detección como la habilidad del sistema para localizar un objeto, independientemente de la predicción de la clase del objeto. Por otro lado, la clasificación de los objetos es analizada de acuerdo a su tamaño respecto al tamaño de la imagen.

Por tanto, dada una imagen de test de tamaño  $height \times width$  píxeles que considera  $M$  objetos reales en la máscara de verdad, con centroide  $c\_gt_m$  y área  $a\_gt_m$  para un objeto real  $m \in \{1, \dots, M\}$ , y dada una propuesta que estima  $N$  objetos predichos, con centroide  $c\_bw_n$  y área  $a\_bw_n$  para el objeto predicho  $n \in \{1, \dots, N\}$ , la detección del objeto real  $m$  es correcta si existe un objeto predicho  $n$  con:

$$dist(c\_gt_m, c\_bw_n) \leq p \cdot \sqrt{height^2 + width^2} \quad (3)$$

donde  $dist$  es la función de distancia euclídea y  $p$  es una constante de proporcionalidad. Es decir, si la distancia entre ambos centroides es menor que  $p\%$  del tamaño de la diagonal de la imagen de test entonces el objeto  $m$  está correctamente detectado. En este estudio se ha considerado  $p = 0,03$ .

Por otro lado, en el proceso de clasificación también se han considerado objetos lejanos y objetos cercanos. Un objeto real  $m$  es lejano si:

$$a\_gt_m < u \cdot (height \cdot width) \quad (4)$$

donde  $u$  es una constante. Un objeto real  $m$  es cercano si no es lejano. En este estudio se ha considerado  $u = 0,05$ .

Primero, en la primera fila de la Tabla I se muestra la velocidad de procesado para la tarea de detección de objetos. Estos valores fueron medidos teniendo en cuenta solo la función de detección, que esencialmente hace uso de la GPU a través de CUDA v9.0. Darknet es, como se puede comprobar en la tabla, el mejor marco de trabajo en términos de velocidad de procesado en el proceso de detección. Es seguido por Pytorch, mientras que Tensorflow estaría en la última posición. Es muy interesante remarcar que la diferencia entre los tiempos de computación obtenidos por YOLO y los otros dos marcos de trabajo son significativamente mayores que las diferencias entre Tensorflow y Pytorch. La razón es que Pytorch y Tensorflow están utilizando una implementación basada en una Fast-RCNN, mientras que darknet\_yolo utiliza

Cuadro I: Tiempos de computación

	Darknet(yolo)	Darknet(yolo-vgg)	Tensorflow	Pytorch
Media segundos por fotograma	0.009	0.011	0.089	0.048
Media fotogramas por segundo	111.738	90.9	11.297	21.011

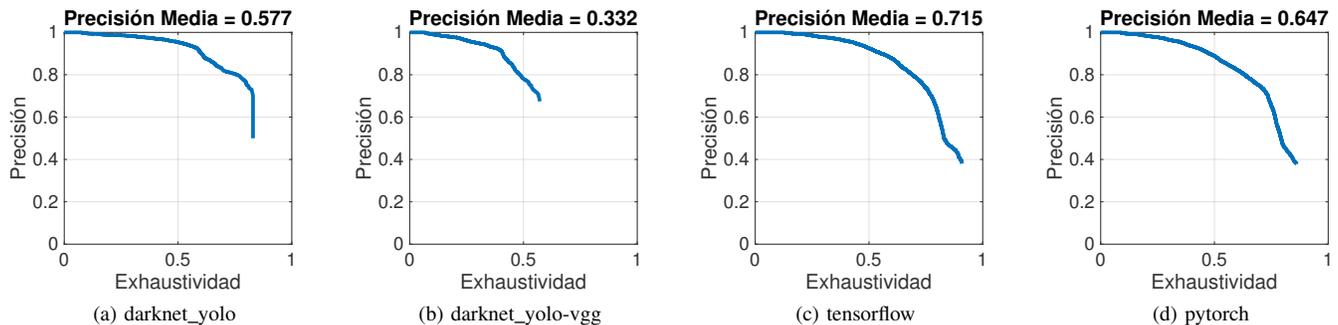


Figura 1: Precisión vs exhaustividad. Las imágenes muestran la figura con la representación del rendimiento en precisión frente a exhaustividad de los diferentes marcos de trabajo (mayor es mejor). La precisión media se calcula como la media de todas las clases de objetos.

un método de evaluación de una sola imagen. Todas las medidas de rendimiento se ven afectadas por este motivo.

Sin embargo, si nos centramos en la exactitud de las detecciones, en la Figura 1 y Tabla II, se puede observar que el mejor rendimiento es obtenido por Tensorflow, seguido por Pytorch. Ambos marcos de trabajo tienen menos falsos negativos en las detecciones de los objetos ya que la exhaustividad es mayor, aunque también es cierto que la precisión es menor que la obtenida por darknet\_yolo, lo que indica un mejor comportamiento en términos de falsos positivos para el sistema.

En cuanto al rendimiento de la clasificación, de los resultados obtenidos en los experimentos y mostrados en la Tabla III y Figura 2, se puede observar que, hablando sobre la correcta identificación de los objetos, Tensorflow tiene el mayor número de objetos localizados correctamente clasificados, seguido de Pytorch. También tiene la mayor exactitud media para los objetos localizados correctamente clasificados. Tensorflow también presenta el menor error de distancia medio y la mayor confianza media en la clasificación.

Para algún usuario que quiera utilizar uno de los sistemas presentados en este estudio sería muy útil saber cuántos objetos del total que son detectados, son clasificados erróneamente. A este respecto, comprobando la segunda fila de la Tabla III, se puede ver que el sistema que presenta el menor número de objetos localizados clasificados erróneamente es YOLO-VGG. Parece que el sistema YOLO-VGG es el que comete menos errores en la tarea de identificación una vez que ha detectado un objeto determinado en la imagen.

Las últimas tres filas de la Tabla III muestran una visión general sobre cuántos objetos no han sido identificados por el sistema y la posible correlación de este número con la posición dentro de la imagen y el tamaño de esos objetos respecto al tamaño de la imagen de test. En la tercera fila se muestra el número total de objetos no identificados por el sistema y de los

valores que aparecen allí, se puede observar que Tensorflow nuevamente supera a sus competidores mostrando el menor número de objetos no identificados, una vez más seguido de Pytorch. En esta fila también aparece el nombre de la clase de aquellos objetos que permanecen como no identificados más frecuentemente. En este caso, los cuatro sistemas concluyen que, en general, los objetos de la clase “persona” son los que más frecuentemente aparecen como no identificados.

También es interesante conocer dónde están esos objetos no identificados en la imagen de test y su tamaño. En este sentido, la cuarta fila de la Tabla III muestra el número de objetos lejanos no identificados y la clase de los objetos lejanos que más frecuentemente no se identifican. Nuestros experimentos señalan que el sistema con el menor número de objetos no identificados es una vez más Tensorflow con su asociado modelo de red basado en VGG-16. Del mismo modo, los objetos lejanos de clase “botella” son los más frecuentemente no identificados. En la última fila de la Tabla III se muestran los resultados para los objetos cercanos no identificados. Ahí se puede observar nuevamente que Tensorflow supera a sus competidores teniendo el menor número de objetos lejanos no identificados, seguido de Pytorch. Igualmente, se puede observar que los objetos de la clase “persona” son los más frecuentemente no identificados por cada sistema.

#### IV. CONCLUSIONES

En este trabajo se ha propuesto un estudio de diferentes sistemas de detección y clasificación de objetos en imágenes digitales. Para ello se han realizado pruebas con cuatro sistemas de detección y clasificación basados en redes neuronales convolucionales: Tensorflow, Pytorch, YOLOv2 y YOLOv2-VGG. Se han llevado a cabo pruebas especializadas con el conjunto de datos estándar VOC calculando medidas de rendimiento adaptadas específicamente para la medición del rendimiento en sistemas de detección donde la posición y el



Cuadro II: Rendimiento de detección

	darknet(yolo)	darknet(yolo-vgg)	tensorflow	pytorch
Número de verdaderos positivos	6216	3404	7992	7198
Número de falsos negativos	5816	8628	4040	4834
Número de falsos positivos	1879	1581	6674	6504
Exhaustividad	0.517	0.283	0.664	0.598
Tasa de falsos negativos	0.483	0.717	0.336	0.402
Precisión	0.768	0.683	0.545	0.525
F-medida	0.618	0.400	0.599	0.559
Exactitud	0.447	0.250	0.427	0.388

Cuadro III: Rendimiento de clasificación

	darknet(yolo)	darknet(yolo-vgg)	tensorflow	pytorch
Objetos correctamente identificados				
Número de objetos localizados correctamente clasificados	5974	3253	7531	6738
Exactitud de objetos localizados correctamente clasificados	0.961	0.956	0.942	0.936
Error de distancia media	7.827	8.815	7.096	7.567
Confianza media	0.827	0.805	0.960	0.969
Objetos localizados incorrectamente clasificados				
Número de objetos localizados incorrectamente clasificados	242	151	461	460
Exactitud de objetos localizados incorrectamente clasificados	0.039	0.044	0.058	0.064
Error de distancia media	9.460	9.353	8.451	8.709
Confianza media	0.773	0.748	0.855	0.880
Objetos no identificados				
Número de objetos no identificados	5816	8628	4040	4834
Área media de los objetos no identificados (píxeles)	37199.04	37199.94	48008.87	47350.94
Clase menos identificada (porcentaje de todos los objetos no identificados)	persona (0.156)	persona (0.145)	persona (0.167)	persona (0.164)
Objetos no identificados (lejanos)				
Número de objetos lejanos no identificados	2060	2889	946	1175
Área media de los objetos lejanos no identificados (píxeles)	3772.41	3931,125	3.962	3.977
Clase de objetos lejanos menos identificada (porcentaje de todos los objetos lejanos no identificados)	botella (0.234)	botella (0.231)	botella (0.290)	botella (0.305)
Objetos no identificados (cercanos)				
Número de objetos cercanos no identificados	3756	5739	3094	3659
Área media de los objetos cercanos no identificados (píxeles)	55532.07	53947.39	61476.31	61279.5
Clase de objetos cercanos menos identificada (porcentaje de todos los objetos cercanos no identificados)	persona (0.182)	persona (0.165)	persona (0.191)	persona (0.188)

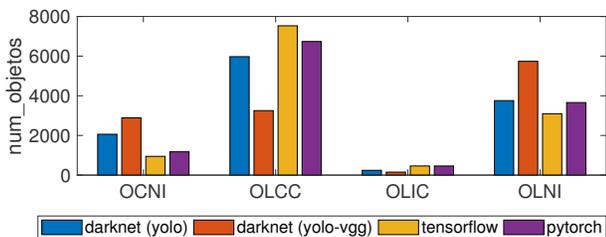


Figura 2: Comparativa de rendimiento de la clasificación de objetos. El número de objetos clasificados por marco de trabajo se muestra de acuerdo a las condiciones consideradas: Objetos Localizados Correctamente Clasificados (OLCC), Objetos Localizados Incorrectamente Clasificados (OLIC), Objetos Cercanos No Identificados (OCNI) y Objetos Lejanos No Identificados (OLNI).

tamaño de un objeto en la imagen de entrada son desconocidos *a priori*.

Los resultados experimentales revelan que Darknet-YOLO

es, por una amplia diferencia, el método más rápido de los cuatro siendo un 18% más rápido que su competidor más directo y el mejor en términos de precisión en la fase de detección. Sin embargo, cuando se trata de precisión en la clasificación, Tensorflow consigue las mejores puntuaciones tanto en la media de la medida de equilibrio precisión-exhaustividad y en número de objetos localizados correctamente clasificados. Los resultados también indican que Pytorch presenta un buen equilibrio entre detección, clasificación y velocidad, lo que lo presenta como un sistema conveniente para su utilización en tareas de detección y clasificación de objetos cuando el usuario está de acuerdo en renunciar a una pequeña cantidad de precisión a cambio de obtener un sistema de detección y clasificación más rápido que funcione casi en tiempo real.

Como una posible extensión del presente trabajo, proponemos extender este estudio a un mayor número de marcos de trabajo para deep learning que actúen como base de sistemas de detección y clasificación de objetos.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Economía, Industria y Competitividad de España, bajo

los proyectos TIN2014-53465-R y TIN2016-75097-P, y por la Junta de Andalucía, bajo los proyectos TIC-6213 y TIC-657. Todos los proyectos incluyen fondos FEDER. Los autores quieren agradecer los recursos computacionales y asistencia técnica proporcionados por el Servicio de Supercomputación y Bioinformática (SCBI) de la Universidad de Málaga. Así mismo, también quieren agradecer a NVIDIA Corporation por la donación de 2 GPUs Titan X para su investigación. Karl Thurnhofer-Hemsi (FPU15/06512) está disfrutando de una beca de doctorado del Ministerio de Educación, Cultura y Deportes bajo el programa FPU.

## REFERENCIAS

- [1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Proceedings of the Advances in Neural Information Processing Systems*, 2012, pp. 1097—1150.
- [2] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *CoRR*, vol. abs/1409.1556, 2014. [Online]. Available: <http://arxiv.org/abs/1409.1556>
- [3] Y. J. P. S. S. R. D. A. D. E. V. V. C. Szegedy, W. Liu and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, 2015, pp. 1–9.
- [4] S. R. K. He, X. Zhang and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, 2016, pp. 770—778.
- [5] C. J. M. A. G. L. S. G. V. D. D. J. S. I. A. V. P. M. L. e. a. D. Silver, A. Huang, “Mastering the game of go with deep neural networks and tree search,” *Nature*, vol. 529, pp. 484—489, 2016.
- [6] A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, P. Martinez-Gonzalez, and J. Garcia-Rodriguez, “A Survey on Deep Learning Techniques for Image and Video Semantic Segmentation,” *Applied Soft Computing*, vol. 70, pp. 41–65, 2018.
- [7] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards real-time object detection with region proposal networks,” in *Advances in Neural Information Processing Systems (NIPS)*, 2015.
- [8] J. Redmon, “Darknet: Open source neural networks in c,” <http://pjreddie.com/darknet/>, 2013–2016.
- [9] J. Redmon and A. Farhadi, “Yolo9000: Better, faster, stronger,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017, pp. 6517–6525.
- [10] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, “The pascal visual object classes (voc) challenge,” *International Journal of Computer Vision*, vol. 88, no. 2, pp. 303–338, Jun. 2010.
- [11] —, “The PASCAL Visual Object Classes Challenge 2007 (VOC2007) Results,” <http://www.pascal-network.org/challenges/VOC/voc2007/workshop/index.html>.
- [12] —, “The PASCAL Visual Object Classes Challenge 2012 (VOC2012) Results,” <http://www.pascal-network.org/challenges/VOC/voc2012/workshop/index.html>.
- [13] X. Chen and A. Gupta, “An implementation of faster rcnn with study for region sampling,” *arXiv preprint arXiv:1702.02138*, 2017.
- [14] J. Yang, J. Lu, D. Batra, and D. Parikh, “A faster pytorch implementation of faster r-cnn,” <https://github.com/jwyang/faster-rcnn.pytorch>, 2017.
- [15] H. Schütze, C. D. Manning, and P. Raghavan, *Introduction to information retrieval*. Cambridge University Press, 2008, vol. 39.
- [16] D. Hoiem, Y. Chodpathumwan, and Q. Dai, “Diagnosing error in object detectors,” in *European conference on computer vision*. Springer, 2012, pp. 340–353.
- [17] P. Dollar, C. Wojek, B. Schiele, and P. Perona, “Pedestrian detection: An evaluation of the state of the art,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 34, no. 4, pp. 743–761, 2012.



# Adaptación automática del operador de *pooling* aprendiendo pesos de medias ponderadas ordenadas en Redes Neuronales Convolucionales

Juan I. Forcén

*Das-nano — Veridas*  
Poligono Industrial Talluntxe II  
Tajonar, España  
jiforcen@das-nano.es

Miguel Pagola

*dept. Estadística Informática y Matemáticas*  
Universidad Pública de Navarra  
Pamplona, España  
miguel.pagola@unavarra.es

Edurne Barrenechea

*dept. Estadística Informática y Matemáticas*  
Universidad Pública de Navarra  
Pamplona, España  
edurne.barrenechea@unavarra.es

Humberto Bustince

*dept. Estadística Informática y Matemáticas*  
Universidad Pública de Navarra  
Pamplona, España  
bustince@unavarra.es

**Resumen**—Las Redes Neuronales Convolucionales (RNCs) han logrado ser los modelos de mayor precisión en varias tareas de visión por computador. Tienen estructuras cada vez más complejas en las que se deben seleccionar un buen número de parámetros, como el número de capas, los filtros por capa o las capas de re-muestreo conocidas como *pooling*. En la capa de *pooling* las activaciones de los píxeles vecinos se agregan de forma local; el máximo y la media ponderada son las funciones de agregación comúnmente utilizadas. En este trabajo presentamos una nueva forma de agregar a través de medias ordenadas ponderadas, de tal forma que los pesos de las medias se aprenden durante el entrenamiento de la red. De esta forma el operador de *pooling* se selecciona automáticamente durante el entrenamiento de la red. Por lo tanto, la RNC tiene unos hiper-parámetros menos que no debemos seleccionar. En los resultados experimentales mostramos que la precisión y la capacidad de generalizar de las redes que utilizan este tipo de operador es similar a las redes con operadores de *pooling* fijados.

**Index Terms**—Clasificación, Redes Neuronales Convolucionales, Pooling, Máximo, Medias ponderadas ordenadas

## I. INTRODUCCIÓN

Las Redes Neuronales Convolucionales (RNCs) que están inspiradas en cómo funciona la corteza visual, consisten en múltiples capas de filtros convolucionales de una o más dimensiones [1]. En el ámbito de la clasificación de imágenes las RNCs son el estado del arte en cuanto a precisión y han cambiado el paradigma del procesamiento de imágenes tradicional, ya que las características se aprenden durante el proceso de entrenamiento de la red. Las RNCs son utilizadas en reconocimiento de objetos, conducción automática o reconocimiento del habla [2].

La estructura de una RNC es una serie de capas convolucionales seguidas de capas de *pooling* y finaliza con una serie de capas de neuronas completamente conectadas. El objetivo de cada capa convolucional es producir representaciones que

reflejen características locales de la imagen. Cada capa convolucional consta de múltiples canales en los que las características están representadas según los valores de activación. En las capas de *pooling* se agregan las activaciones de cada región de cada canal de la capa de convolución precedente. Este paso se utiliza para obtener una representación más compacta, más robusta e invariante a las transformaciones de las imágenes. A pesar de tener una influencia muy grande en el funcionamiento de la red, la operación de *pooling* no ha sido muy estudiada y la mayor parte de modelos utilizan el máximo o la media aritmética [3]. Al utilizar operadores fijos, en las capas de *pooling* no se aprende ningún parámetro, sin embargo, el tipo de operador de *pooling* que se utiliza en cada una de las capas pasa a ser un hiper-parámetro más de la red. Por lo tanto, pasa a ser otro de los problemas de las RNCs, el alto número de hiper-parámetros [4] (número de capas de la red, número de filtros por capa, el tamaño de los filtros, ratio de aprendizaje, tamaño del subconjunto de entrenamiento, etc.). Debido al alto número de hiper-parámetros, la selección para un problema dado de la arquitectura de red más adecuada tiene un alto coste computacional.

En este trabajo proponemos utilizar como operador de *pooling* medias ponderadas ordenadas [5], cuyos pesos son aprendidos en la fase de entrenamiento. Al ser una media ponderada aseguramos que el resultado de la agregación está siempre entre el máximo y el mínimo valor de los elementos agregados. Por lo tanto, durante del proceso de entrenamiento los valores de los pesos pueden ajustarse a que el operador resultante sea el máximo, la media aritmética o cualquier otro operador que resulte en una red con mejor precisión en el conjunto de entrenamiento.

En la validación experimental hemos comprobado que (en las arquitecturas que hemos probado) si reemplazamos los operadores de *pooling* clásicos por nuestra propuesta, se

alcanza una precisión igual o superior en varios conjuntos de imágenes (CIFAR-10, CIFAR-100, FMNIST).

El trabajo se divide en las siguientes secciones: en la sección II realizamos un análisis de la operación de *pooling* y repasamos los trabajos relacionados. En la sección III describimos el método propuesto y en la sección IV presentamos los resultados obtenidos en los diferentes experimentos. Acabamos con las conclusiones y posibles trabajos futuros.

## II. ANÁLISIS DE LA OPERACIÓN DE *pooling*

La operación de *pooling*, a veces conocida como de muestreo, es un paso crucial en varios sistemas de reconocimiento de imágenes como el modelo *Bag-of-Words*, el método VLAD [6], el Super Vector [7] o las RNCs. Dos factores definen la operación de *pooling*: uno es la región de la imagen cuyas características locales se van a agregar y el otro factor es la operación de agregación que define la forma combinar dichas características locales.

En este trabajo nos vamos a centrar en la forma de agregar los valores de las características. Los operadores más comunes son el máximo, utilizado en las arquitecturas de redes más conocidas (AlexNet [8], VGG [9]) y la media aritmética que se utiliza en otros modelos (p.e. en Network in Network [11] o GoogleNet [10]). Recordemos que en la operación de *pooling* simplemente tomamos una ventana de tamaño  $n \times n$  de una imagen de características y obtenemos un único valor. Deslizándola la ventana de  $n$  en  $n$  píxeles a lo largo de toda la imagen obtendremos una nueva imagen de menor dimensión que la original.

Boureau et. al. [3], analizó el método conocido como *Spatial Pyramid* [12] e identificó mucho mejor rendimiento en clasificación en varios conjuntos de imágenes utilizando el máximo frente a la media aritmética. Más aún, en [13] Boureau et. al. desarrollaron un estudio teórico en el que demuestran que utilizar el máximo en la fase de agregación de vectores de características es adecuado cuando las características que definen a una clase tienen poca probabilidad de activación. Este resultado fue validado experimentalmente en [14] y en [15]. En ambos trabajos, el operador máximo obtiene los mejores resultados cuando se utilizan vectores dispersos de características muy grandes. En los vectores de características dispersos, cada característica tiene poca probabilidad de activación (es decir que su valor sea mayor que cero) y tiene mucho poder discriminatorio. Sin embargo, cuando se utilizan operadores de *pooling* que suavizan el valor máximo (el máximo esperado en [13] y otras metodologías en [14]) se obtienen todavía mejores resultados que con el máximo. Similar resultado obtuvimos en [16], donde estudiamos la cardinalidad del operador de *pooling* que realiza la media sobre los  $\mathcal{N}$  valores mayores (utilizando *Bag-of-Words* y *Spatial Pyramid*). Además en [17] comprobamos que las medias ponderadas ordenadas también dan buenos resultados en dicha metodología de clasificación de imágenes. En [14] y [13] se argumenta que las conclusiones obtenidas se pueden trasladar a la operación de *pooling* de las RNCs, ya que si aplicamos el método de *Bag-of-Words* en diferentes capas, el modelo global es equivalente a una RNC.

Pensemos en una red con una estructura con varias capas. Si en la imagen que estamos tratando existe, por ejemplo, una esquina muy definida, habrá un valor de activación muy alto en una imagen de características en la que se representen las esquinas. Por lo tanto, si en las restantes capas de *pooling* utilizamos el operador máximo, este valor (que es muy alto) se va a ir propagando por la arquitectura de la red y llegará a formar parte de la representación final de características de la imagen. Si dicha esquina es representativa de la clase de la imagen, entonces será una característica discriminatoria y servirá para clasificar correctamente la imagen.

Por otro lado, imaginemos que por toda la imagen hay una textura que no está claramente definida, pero que representa a la clase de la imagen. El valor de activación en la imagen de características de esa textura será pequeño. Si el operador de *pooling* en todas las capas es el máximo, el valor que se propaga por la red es pequeño y por lo tanto desaparecerá o no tendrá mucha representación en el vector final. Sin embargo, si el operador utilizado es la media aritmética, al aparecer la textura por toda la imagen, su representación en el vector final será mayor. Esto es debido a que las características que aparecen aisladamente son filtradas por la media y acaban teniendo un valor más pequeño en la representación final.

Teniendo en cuenta que el máximo y la media son operadores adecuados para diferentes tipos de características, en [18] se proponen dos métodos en los que se aprende la función de *pooling*. En la primera estrategia, se aprende un parámetro que mezcla el resultado del valor máximo con la media aritmética. En el segundo método se aprende una función de *pooling* en forma de árbol que va mezclando los resultados de diferentes filtros de *pooling*. Estos filtros también se aprenden y son idénticos a los filtros de convolución. En ambos casos obtiene mejores resultados que si se utilizan operadores de *pooling* fijos. Sin embargo, la segunda estrategia es similar a añadir nuevas capas de convolución, por lo tanto, no puede considerarse una generalización de la operación de *pooling*. En este trabajo proponemos un método de *pooling* en el que se aprenda una función de *pooling*. El objetivo es aprender unos coeficientes que afecten únicamente a los valores de las activaciones (en el caso de la convolución los pesos están asociados a su posición espacial en el filtro). Para ello utilizaremos medias ordenadas ponderadas, en las que el vector de valores se ordena de mayor a menor y después cada valor es multiplicado por el coeficiente asociado a cada posición del vector ordenado. Los valores de los pesos se aprenderán en la fase de entrenamiento. De esta forma, nos proponemos obtener un operador de *pooling* que propague los valores más altos de las activaciones, teniendo en cuenta también los valores de activaciones medios que aparezcan frecuentemente.

## III. *Pooling* BASADO EN MEDIAS PONDERADAS ORDENADAS

Los operadores estándar de *pooling* son o el máximo  $f_{max}(\mathbf{x}) = \max_{i \in \mathcal{N}} \{x_i\}$  o la media aritmética  $f_{med} =$



$\frac{1}{N} \sum_{i \in N} \mathbf{x}_i$ , donde el vector  $\mathbf{x}$  contiene los valores de activación de una región de *pooling* local de tamaño  $N$  píxeles (típicamente 2x2 o 3x3).

Las medias ponderadas ordenadas son funciones de agregación promedio. Se diferencian de las medias ponderadas en que los pesos no están asociados a unas posiciones del vector de entrada sino a las magnitudes. Fueron propuestas por Yager en 1988 [5].

$$f_{mpo}(\mathbf{x}_i \searrow) = \sum_{i \in N} w_i x_i \quad (1)$$

Donde  $(\mathbf{x}_i \searrow)$  es un vector ordenado con  $x_1 \geq x_2 \geq \dots \geq x_N$ . La suma de pesos debe ser igual a uno  $\sum_{i=1}^n w_i = 1$  y  $w_i \geq 0$  para cada  $i = 1, \dots, n$ .

El cálculo de la media ponderada ordenada requiere de la ordenación de los valores que van a ser agregados. Dependiendo de los valores de los pesos podemos obtener las funciones de agregación típicas [19], por ejemplo:

- Si  $w = (0, 0, \dots, 0, 1)$ , entonces  $f_w = \text{mínimo}$ .
- Si  $w = (1, 0, \dots, 0, 0)$ , entonces  $f_w = \text{máximo}$ .
- Si  $w = (\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}, \frac{1}{n})$ , entonces  $f_w = \text{media aritmética}$ .
- Si  $w = (0,5, 0,5, 0, 0, 0, 0, 0, 0, 0)$ , entonces  $f_w = \text{media de los dos valores mayores}$ .

Cuando utilizamos un operador de *pooling* con medias ponderadas ordenadas tenemos varias posibilidades, aprender unos pesos por red, por capa, por cada canal de cada capa o incluso de cada región de cada canal de cada capa. A continuación vamos a desarrollar las ecuaciones para el caso de aprender un conjunto de pesos en una capa de la red. Sea la función de coste de la red  $J$ , creamos una nueva función de coste en la que añadimos tres términos. El primer término fuerza que los valores sean mayores que cero, el segundo obliga a que la suma de pesos sea 1 y el tercer término penaliza las diferencias entre los pesos consecutivos. Al utilizar estos términos (similares a una regularización) obtenemos unos valores de los pesos que serán más interpretables.

$$J_{mpo} = J + C_1 \sum_{i=1}^N \max\{0, -w_i\} + C_2 \left( \left( \sum_{i=1}^N w_i \right) - 1 \right)^2 + C_3 \left( \sum_{i=1}^{N-1} (w_i - w_{i+1})^2 \right)$$

Por lo tanto el cálculo del gradiente para utilizarlo en el algoritmo de optimización queda:

$$\Delta_{w_i} J_{mpo} = \Delta_{w_i} J - C_1 + 2C_2 \left( \left( \sum_{i=1}^N w_i \right) - 1 \right) w_i + 2C_3 (w_i - w_{i+1}) \quad (2)$$

Si  $w_i \geq 0$  el término  $C_1$  desaparece. El cálculo del gradiente  $\Delta_{w_i} J$  es similar al de una capa de convolución. Teniendo en cuenta que en lugar de la convolución, hay que ordenar los valores de la capa de activación.

#### IV. RESULTADOS EXPERIMENTALES

En la fase de experimentación queremos comprobar la precisión de RNCs ya conocidas y validadas cuando sustituimos el operador de *pooling* original por el operador de *pooling*

basado en medias ordenadas ponderadas. Además queremos comprobar si los pesos convergen hacia unos operadores de *pooling* similares a los operadores originales  $((1, 0, 0, \dots, 0)$  para el máximo o  $(\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n})$  para la media). Los modelos de red que utilizaremos son dos: la red propuesta en [11] que es conocida como Network in Network (NiN) y el modelo VGG [9]. Ambas arquitecturas quedan reflejadas en la tabla I y el tabla II respectivamente (todas las convoluciones van seguidas de activaciones tipo Relu).

Cuadro I  
PARÁMETROS DE LA RED NiN

Input		Filtros, canales
32x32		5x5, 192
32x32		1x1, 160
32x32		1x1, 96
32x32	pool1	3x3 Max <i>pooling</i> , stride 2
16x16		dropout 0.5
16x16		5x5, 192
16x16		1x1, 192
16x16		1x1, 192
32x32	pool2	3x3 Med <i>pooling</i>
8x8		dropout 0.5
8x8		5x5, 192
8x8		1x1, 192
8x8		1x1, 10 o 100
8x8	pool3	8x8 Med <i>pooling</i>
10 o 100		Softmax

Cuadro II  
PARÁMETROS DE LA RED VGG

Input		Filtros, canales
28x28		3x3, 64
28x28		3x3, 64
28x28	pool1	2x2 Max <i>pooling</i> , stride 2
14x14		3x3, 128
14x14		3x3, 128
14x14	pool2	2x2 Max <i>pooling</i> , stride 2
7x7		3x3, 256
7x7		3x3, 256
7x7	pool3	2x2 Max <i>pooling</i> , stride 2
4x4		3x3, 512
4x4		3x3, 512
4x4	pool4	2x2 Max <i>pooling</i> , stride 2
2x2		3x3, 512
2x2		3x3, 512
2x2	pool5	2x2 Max <i>pooling</i> , stride 2
-		Flatten
-		2048
-		512
-		10
-		Softmax

Hemos utilizado los conjuntos de imágenes CIFAR-10, CIFAR-100 [20] y Fashion-MNIST [21]. Los datasets CIFAR-10 y CIFAR-100 contienen 50000 imágenes a color para la fase de entrenamiento y 10000 de test. Tienen 10 y 100 categorías respectivamente, mientras que FMNIST contiene 60000 imágenes en escala de grises para entrenamiento y 10000 de test (10 categorías). Las imágenes de CIFAR-10 y

CIFAR-100 tienen una resolución de 32x32 píxeles, mientras que las de FMNIST de 28x28.

En la tabla III mostramos los resultados obtenidos para la red NiN en los conjuntos de datos CIFAR-10 y CIFAR-100. En la primera fila se muestra el porcentaje de acierto en los conjuntos de test. En la fila Max se muestra el resultado cuando los operadores de todas las capas son *pooling* el máximo. En la fila Med todos los operadores de *pooling* son la media aritmética. Las filas con MPO1 corresponden a cuando entrenamos en todas las capas de *pooling* una media ponderada ordenada. En el caso MPO2 entrenamos un operador por cada canal de cada capa. En la fila MPO1ft, se muestran los resultados cuando entrenamos la red con todos los operadores de *pooling* con la media aritmética y cuando el entrenamiento converge, se sustituyen los operadores de *pooling* por medias ponderadas ordenadas, se fijan los pesos de las capas convolucionales y se entrena durante unas pocas épocas para que se ajusten los pesos de las capas de *pooling*. Este método es similar al conocido *fine tuning*. En el resto de filas el sufijo pl significa que el entrenamiento de los pesos del operador de *pooling* se realiza sin añadir los términos de regularización a la función de coste. De tal manera que los pesos convergen a valores que no cumplen las condiciones para ser una media ponderada (es decir, no tienen que ser positivos ni sumar 1). En la tabla IV se muestran los resultados de la red VGG en FMNIST (en el modelo original todos los operadores de *pooling* son el máximo).

Observando los resultados comprobamos que los modelos en los que se utilizan las MPOs alcanzan una precisión parecida al modelo original. Un poco menor en VGG y un poco mayor en el caso de NiN para CIFAR-100. Cuando se entrenan los pesos libres la precisión es un poco mayor a cuando los pesos cumplen las condiciones de las MPOs. También se comprueba que ajustar un operador de *pooling* por cada canal de cada capa no es necesario, de hecho la precisión de MPO2 es más baja que MPO1 en todos los casos. Por lo tanto, podemos utilizar las MPOs para encontrar modelos de red sin tener que identificar manualmente cuáles son los operadores de *pooling* adecuados para cada capa.

Cuadro III  
RESULTADOS EXPERIMENTALES DE LA RED NiN

NiN	CIFAR-10	CIFAR-100
Orig	90.24	58.70
Max	88.76	54.89
Med	90.50	58.75
MPO1	90.34	59.33
MPO2	90.32	58.09
MPO1ft	90.39	59.42
MPO1pl	<b>90.58</b>	<b>59.66</b>
MPO2pl	90.36	58.77
MPO1pl-ft	90.46	59.62

*IV-1. Test robustez:* Al añadir más parámetros a la red que se entrenan cabe pensar que obtendremos redes que están más ajustadas y por tanto con menos capacidad de generalización. Para comprobar este hecho hemos realizado un test de robustez

Cuadro IV  
RESULTADOS EXPERIMENTALES DE LA RED VGG.

VGG	FMNIST
Max	<b>94.31</b>
Mean	92.90
MPO1	93.57
MPO2	92.11
MPO1ft	92.87
MPO1pl	94.25
MPO2pl	92.91
MPO1pl-ft	92.770

[18]. En este test, se rotan las imágenes de test entre -8 y 8 grados y se comprueba la precisión (Figuras 1, 2, 3). Comprobamos que en el caso de NiN, el modelo con MPO es el más robusto a los cambios y en VGG es prácticamente igual al modelo original en el que todos los operadores de *pooling* son el máximo. Por lo tanto, ponderar las activaciones teniendo en cuenta únicamente su valor, provoca que las características representativas de la imagen se propaguen por la red hasta la representación final y mejoren la clasificación.

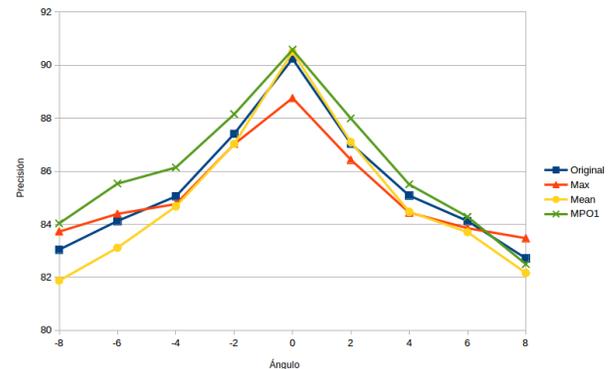


Figura 1. Test de Robustez giro NiN en CIFAR-10.

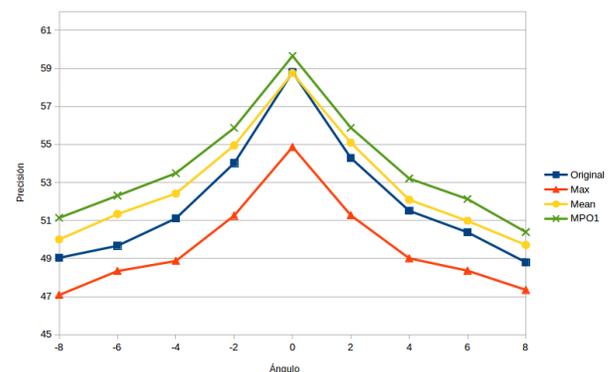


Figura 2. Test de Robustez giro NiN en CIFAR-100.

*IV-2. Análisis de los pesos:* En la figura 4 vemos los 9 pesos de las dos primeras capas de *pooling* de la red NiN en el caso MPO1 cuando entrenamos la red para CIFAR-10 y CIFAR-100 respectivamente. En el modelo original los

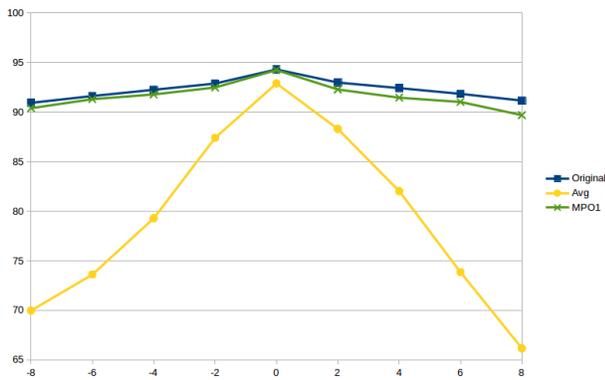


Figura 3. Test Robustez giro VGG en FMNIST.

operadores utilizados son el máximo para la primera capa y la media aritmética para la segunda capa de *pooling*. El coeficiente 1 multiplica al valor mayor y así sucesivamente. En el caso de CIFAR-100, vemos que todos los pesos son prácticamente iguales (ligeramente descendentes), por lo tanto el resultado de estos operadores será muy similar a la media aritmética. Sin embargo, al entrenar la red con CIFAR-10 los coeficientes de cada capa son diferentes. Aunque en ambos casos se obtienen coeficientes mayores para los valores más pequeños, es decir que el valor resultante será incluso más pequeño que la media.

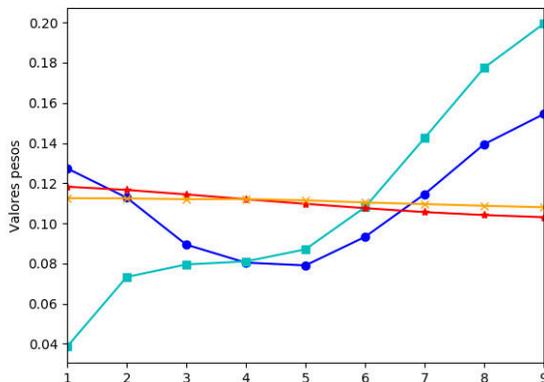


Figura 4. Azul: pesos de la capa pool1 entrenando en CIFAR-10; Cyan pesos de la capa pool2 entrenando en CIFAR-10; Rojo: pesos de la capa pool1 entrenando en CIFAR-100; Naranja pesos de la capa pool2 entrenando en CIFAR-100.

En la figura 5 vemos los 64 pesos de la tercera capa de *pooling* de la red NiN en el caso MPO1 cuando entrenamos la red para CIFAR-10 y CIFAR-100 respectivamente. Los pesos obtenidos con CIFAR-10 son similares a las capas pool1 y pool2, los pesos más grandes multiplican a los valores pequeños. Esto significa que se da importancia a las activaciones de menor valor. Para el caso de CIFAR-100 los pesos son parecidos a la media aritmética (los valores negativos se deben a que el factor de regularización no ha penalizado lo suficiente

y el entrenamiento ha convergido sin llevar ese término a cero).

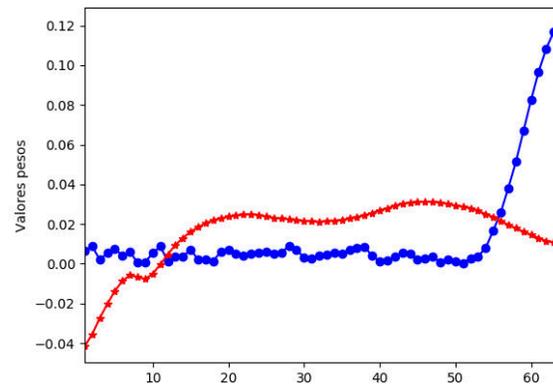


Figura 5. Azul: pesos de la capa pool3 entrenando en CIFAR-10; Rojo: pesos de la capa pool3 entrenando en CIFAR-100.

Al fijarnos en la precisión obtenida por los modelos vemos que MPO1 para CIFAR-100 es bastante mejor que el modelo original y en CIFAR-10 es un poco peor.

En la figura 6 mostramos los 4 pesos obtenidos para las 5 capas de *pooling* de la red VGG (en el modelo original todos los operadores son el máximo). En este caso las capas 1, 3, 4 y 5 convergen a un operador que da más peso a los valores más altos. Sin embargo, los pesos de la segunda capa dan más importancia a los valores pequeños. Puede ser que este sea el motivo de que la precisión del modelo MPO1 es menor que la del modelo original. Por lo tanto, nos queda por comprobar si al lanzar más entrenamientos obtenemos modelos que obtienen una precisión mejor y cuales son los valores de los pesos.

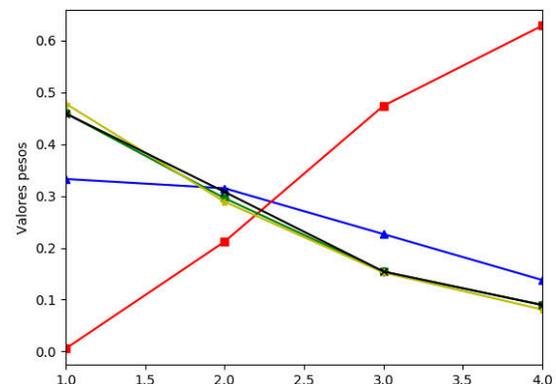


Figura 6. Pesos de las capas pool1 (en azul), pool2 (en rojo), pool3 (en verde), pool4 (en amarillo) y pool5 (en negro) de la red VGG (MPO1) para FMNIST.

*IV-3. Análisis de los tiempos:* El mayor problema de las medias ponderadas ordenadas es la necesidad de ordenar el vector de valores que queremos agregar. Al introducir esta ordenación en la fase de entrenamiento, hace que los tiempos de

computación crezcan. En el tabla V mostramos la proporción de tiempo de los diferentes modelos con respecto al original. El costo en tiempo del modelo MPO1 es demasiado grande y probablemente sea más rápido probar dos o tres combinaciones de operadores de *pooling* basándonos en nuestra experiencia. Sin embargo, si entrenamos con todos los operadores siendo la media y luego realizamos el ajuste de los pesos de los operadores, simplemente doblamos el tiempo del modelo original y obtenemos un modelo robusto y con una precisión similar al mejor modelo. Por lo tanto, si utilizamos esta metodología, el uso de medias ponderadas puede utilizarse en casos reales en los que no conozcamos la arquitectura correcta e introducimos en la fase de entrenamiento la selección del operador de *pooling*.

Cuadro V  
TIEMPOS DE ENTRENAMIENTO

NiN	Orig	Max	Med	MP01	MPO1ft
Tiempo	1	1.02x	0.95x	4.06x	1.69x
VGG	Orig	Max	Med	MPO1	MPO1ft
Tiempo	1	1	0.83x	7.26x	2.11x

## V. CONCLUSIONES Y TRABAJOS FUTUROS

En este trabajo hemos propuesto aprender los pesos de medias ponderadas ordenadas para adaptar automáticamente el operador de *pooling*. De esta forma eliminamos un hiperparámetro a la hora de seleccionar la estructura de la red. En las pruebas experimentales hemos comprobado que añadiendo muy pocos parámetros, aprendiendo un único operador por capa, el *pooling* basado en medias ponderadas obtiene una precisión similar a los modelos originales, teniendo la red obtenida una mayor precisión frente a variaciones de las imágenes de test. Como trabajo futuro falta por analizar las condiciones iniciales y los parámetros del entrenamiento para comprobar que se ha convergido a la mejor solución o si es posible obtener otros pesos que mejoren la precisión de la red. Otro posible estudio consiste en relacionar el operador de *pooling* a la zona de la imagen original. Teniendo en cuenta que la estructura de la imagen original se mantiene a lo largo de las capas de la red, en lugar de aprender un operador por cada canal, el objetivo es aprender un operador por cada zona.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto TIN2016-77356-P (AEI/FEDER, UE).

## REFERENCIAS

[1] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, "Backpropagation applied to handwritten zip code recognition," *Neural Computation*, vol. 1, pp. 541–551, Dec 1989.

[2] N. Aloysius and M. Geetha, "A review on deep convolutional neural networks," in *2017 International Conference on Communication and Signal Processing (ICCSPP)*, pp. 0588–0592, April 2017.

[3] Y. L. Boureau, F. Bach, Y. LeCun, and J. Ponce, "Learning mid-level features for recognition," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 2559–2566, 2010.

[4] Y. Bengio, *Practical Recommendations for Gradient-Based Training of Deep Architectures*, pp. 437–478. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.

[5] R. Yager, "On ordered weighted averaging aggregation operators in multi criteria decision making," *IEEE Trans. Syst. Man Cybern.*, vol. 18, no. 1, pp. 183–190, 1988.

[6] F. Perronnin, M. Douze, S. Jorge, C. Schmid, F. Perronnin, M. Douze, S. Jorge, and P. Patrick, "Aggregating local image descriptors into compact codes Aggregating local image descriptors into compact codes," 2012.

[7] X. Zhou, K. Yu, T. Zhang, and T. S. Huang, "Image classification using super-vector coding of local image descriptors," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 6315 LNCS, no. PART 5, pp. 141–154, 2010.

[8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, NIPS'12, (USA)*, pp. 1097–1105, Curran Associates Inc., 2012.

[9] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *CoRR*, vol. abs/1409.1556, 2014.

[10] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1–9, June 2015.

[11] M. Lin, Q. Chen, and S. Yan, "Network in network," *CoRR*, vol. abs/1312.4400, 2013.

[12] S. Lazebnik, C. Schmid, and J. Ponce, "Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2, pp. 2169–2178, 2006.

[13] Y.-L. Boureau, J. Ponce, and Y. LeCun, "A Theoretical Analysis of Feature Pooling in Visual Recognition," *Icml*, pp. 111–118, 2010.

[14] P. Koniusz, F. Yan, and K. Mikolajczyk, "Comparison of mid-level feature coding approaches and pooling strategies in visual concept detection," *Computer Vision and Image Understanding*, vol. 117, pp. 479–492, may 2013.

[15] C. Wang and K. Huang, "How to use Bag-of-Words model better for image classification," *Image and Vision Computing*, vol. 38, pp. 65–74, 2015.

[16] M. Pagola, J. I. Forcen, E. Barrenechea, J. Fernández, and H. Bustince, "A study on the cardinality of ordered average pooling in visual recognition," in *Pattern Recognition and Image Analysis (L. A. Alexandre, J. Salvador Sánchez, and J. M. F. Rodrigues, eds.)*, (Cham), pp. 437–444, Springer International Publishing, 2017.

[17] M. Pagola, J. I. Forcen, E. Barrenechea, C. Lopez-Molina, and H. Bustince, "Use of owa operators for feature aggregation in image classification," in *2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pp. 1–6, July 2017.

[18] C. Y. Lee, P. Gallagher, and Z. Tu, "Generalizing pooling functions in cnns: Mixed, gated, and tree," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, pp. 863–875, April 2018.

[19] G. Beliaikov, H. B. Sola, and T. C. Sánchez, *A Practical Guide to Averaging Functions*. Springer, 2016.

[20] A. Krizhevsky, "Learning multiple layers of features from tiny images," tech. rep., 2009.

[21] H. Xiao, K. Rasul, and R. Vollgraf, "Fashion-mnist: a novel image dataset for benchmarking machine learning algorithms," 2017.



# Uso de técnicas de Saliency para Selección de Características

Brais Cancela  
LIDIA Group  
Universidade da Coruña  
A Coruña, Spain  
brais.cancela@udc.es

Verónica Bolón-Canedo  
LIDIA Group  
Universidade da Coruña  
A Coruña, Spain  
veronica.bolon@udc.es

Amparo Alonso-Betanzos  
LIDIA Group  
Universidade da Coruña  
A Coruña, Spain  
ciamparo@udc.es

João Gama  
LIAAD Group  
University of Porto  
Porto, Portugal  
jgama@fep.up.pt

**Resumen**—Las técnicas clásicas de selección de características buscan la eliminación de aquellas características que son irrelevantes o redundantes, obteniendo un subconjunto de características relevantes, que ayudan a una mejor extracción de conocimiento del problema a tratar, permitiendo modelos de aprendizaje más sencillos y fáciles de interpretar. La gran mayoría de estas técnicas trabajan sobre el conjunto completo de datos, pero no nos proporcionan una información detallada caso por caso, que es el escenario del que partimos en esta propuesta. En este trabajo mostraremos un nuevo método de selección de características, basado en las técnicas de saliency en deep learning, que es capaz de proporcionar un conjunto de características relevantes muestra a muestra, y finalmente proporcionar un subconjunto final de las mismas.

**Index Terms**—selección de características, deep learning, saliency

## I. INTRODUCCIÓN

Con el auge del denominado *Big Data*, el uso de técnicas que permitan reducir la dimensionalidad del espacio de entrada se hace cada vez más necesario. Las técnicas que acometen esta tarea se dividen, habitualmente, en dos grandes grupos: la *selección de características* (feature selection) y la *extracción de características* (feature extraction). En la Figura 1 podemos ver una representación gráfica sobre su funcionamiento.

Por una parte, las técnicas de extracción de características reducen el número de características mediante la combinación de las variables originales. Un ejemplo en *Deep Learning* serían las conocidas como *deep features*, que son las características que se utilizan como entrada de la última capa de una red. De esta manera, estas técnicas son capaces de crear un nuevo conjunto de características, que suele ser más compacto y con una capacidad mayor de discriminación. Esta es la técnica más utilizada en análisis de imágenes, procesamiento de señales o en recuperación de la información.

Por otra parte, las técnicas de selección de características consiguen la reducción de la dimensionalidad mediante la eliminación de características tanto irrelevantes como redundantes. Debido al hecho de que la selección de características mantiene los atributos *originales*, es una técnica especialmente

Brais Cancela agradece el apoyo de la Xunta de Galicia bajo su programa postdoctoral. También agradecemos su ayuda a NVIDIA, que nos ha facilitado una tarjeta Titan Xp bajo el ‘GPU Grant Program’.

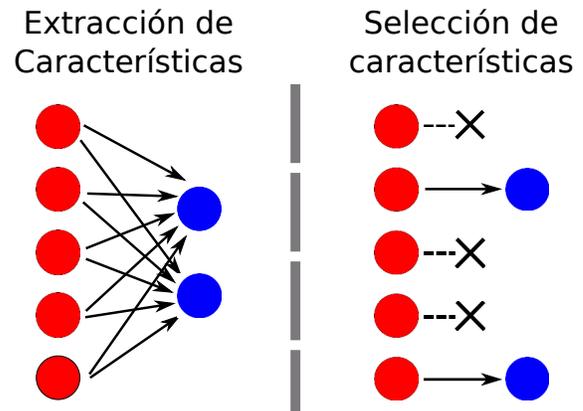


Figura 1. La extracción de características crea nuevas características mediante la combinación del conjunto inicial, mientras que la selección de características elimina aquellas que considera irrelevantes o redundantes, manteniendo inalteradas las restantes.

útil para aplicaciones donde los atributos originales son importantes para la interpretación del modelo y la extracción de conocimiento.

Uno de los problemas de los que adolece la selección de características es que, a pesar de ayudar a extraer un conocimiento más transparente y explicable acerca de las variables que son relevantes para el problema que estemos tratando, lo hace de una manera global. Esto es, no provee información caso por caso. Veamos un ejemplo: supongamos que tenemos un conjunto de datos de pacientes, y nos interesa predecir si un paciente concreto es propenso a padecer cáncer o no. Los métodos de selección de características son capaces de indicarnos cuáles son las características que más influyen a la hora de realizar dicha clasificación. Pero supongamos que tenemos un paciente, y queremos saber, exactamente, cuáles son las características que le han indicado al sistema que dicho paciente es propenso a padecer cáncer. Los sistemas clásicos de selección de características son incapaces de proveer dicha información.

En este trabajo proponemos abordar el problema de selección de características partiendo de este escenario. Nuestra idea propone la utilización de técnicas que nos indiquen, caso por caso, cuáles son las características de cada uno con la información más discriminante. Una vez detectadas, creare-

mos un algoritmo de selección de características, incluyendo aquéllas con un valor medio de discriminación más alto.

El resto del artículo estará estructurado de la siguiente manera: la sección II explicará el método que vamos a utilizar para la evaluación de la importancia de cada característica; la sección III propondrá nuestro algoritmo de selección de características, basado en redes neuronales; finalmente, la sección IV ofrecerá resultados experimentales sobre un conjunto de datasets públicos, y la sección V propondrá nuestras conclusiones y trabajos futuros.

## II. SELECCIÓN DE CARACTERÍSTICAS EN DEEP LEARNING

La literatura científica en el campo de métodos de selección de características que hagan uso de modelos de redes neuronales masivas, tales como por ejemplo, las Redes Convolucionales (CNN), es muy escasa en la actualidad. Uno de los trabajos más interesantes es una variante del LASSO para ser utilizada en CNNs, llamada DeepLASSO [1]. El método introduce un factor multiplicativo a los valores de entrada (llamado *máscara*), sobre el que se aplica un factor de regularización equivalente al del método LASSO (norma 1). Los autores de [1] proponen diferentes regularizaciones (LASSO, elastic Net, etc.) sobre la misma estructura. Las restantes aproximaciones a la selección de características en Deep Learning se englobarían dentro del subconjunto de técnicas denominado como *saliency*.

### II-A. Saliency

*Saliency* es una técnica que surge en la visión por computador, con el objetivo de evaluar la *calidad* de cada uno de los píxeles que componen una imagen. Clásicamente, las redes neuronales se han visto como una caja negra, en la que se obtiene cierta salida a partir de los datos de entrada, pero sin ningún tipo de explicación más o menos transparente sobre cómo se ha llegado a esa solución. Actualmente existen dos maneras de calcular esta información de salida: de una manera semi-supervisada, o totalmente supervisada.

Las primeras técnicas que se utilizaron eran del tipo semi-supervisado [2], [3]. Constan de una red que es entrenada como un clasificador (binario o multiclase). Una vez entrenada la red, y dada una imagen de entrada, se realiza una retropropagación desde la salida hasta la entrada, para averiguar cuáles han sido los píxeles que más han influido en la salida esperada.

Los modelos totalmente supervisados son más recientes [4], [5], y son entrenados de una manera distinta. En este caso, se hace uso de la llamada *segmentación semántica*, ya que la salida de la red tiene el mismo tamaño que la imagen de entrada. Además, para cada imagen sabemos cuáles son los píxeles importantes (por ejemplo, si estamos detectando cierto tipo de objeto, los píxeles importantes son aquellos que pertenecen al objeto en cuestión, mientras que el fondo es considerado irrelevante). El modelo entrena la red para que la salida concuerde con nuestra segmentación previa de píxeles importantes. Estos modelos también suelen ser conocidos como *modelos de atención* [6], [7] cuando se utiliza una Red

Neuronal Recursiva (RNN) como último paso para evaluar la calidad de cada píxel.

Las técnicas totalmente supervisadas obtienen mejores resultados, pero tienen un hándicap importante: para entrenar el modelo se necesita saber, a priori, cuáles son las características relevantes de cada uno de los ejemplos de entrada. En el caso de imágenes suele ser sencillo, pero no siempre es posible obtener dicha información, puesto que no siempre se sabe cuáles son las características que contienen la información más discriminante. Por tanto, para nuestro modelo de selección de características, proponemos hacer uso de una técnica de saliency semi-supervisada.

### II-B. Aproximación propuesta

Para nuestro modelo vamos a utilizar una generalización de la idea propuesta en [2]. Sea un conjunto de datos de entrada  $\mathbf{X} \in \mathcal{R}^{N \times R}$ , con  $N$  número de muestras y  $R$  número de características; y  $\hat{\mathbf{Y}} = f(\mathbf{X}; \Theta) \in \mathcal{R}^{N \times C}$  nuestro clasificador, que puede ser tanto un clasificador lineal como una CNN de muchas capas. En este caso  $C$  es el número de clases a evaluar, y  $\Theta$  son los pesos del clasificador que necesitan ser ajustados en la etapa de entrenamiento. Por simplificación, asumimos que los valores de  $f(\mathbf{X}; \Theta)$  son el resultado de aplicar la función softmax, devolviendo la probabilidad de pertenencia a cada clase. Esto es,

$$\sum_{c=1}^C \tilde{y}_c^{(i)} = 1 \quad (1)$$

Para entrenar la red se minimizará una función de pérdida  $\ell(\Theta; f, \mathbf{X}, \mathbf{Y})$ , donde  $\mathbf{Y} \in \mathcal{R}^{N \times C}$  es la codificación binaria de la clase esperada (*one-hot encoding*). En nuestro caso, minimizaremos la función de entropía cruzada (*cross-entropy*), definida como

$$\ell(\Theta; f, \mathbf{X}, \mathbf{Y}) = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_c^{(i)} \log \left( f(\mathbf{x}^{(i)}; \Theta)_c \right) \quad (2)$$

En el caso de nuestra aproximación, se puede utilizar en conjunto con la técnica DeepLASSO [1], en cuyo caso la función de coste se modificaría de la siguiente manera

$$\ell(\Theta, \psi; f, \mathbf{X}, \mathbf{Y}) = \|\psi\|_1 - \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_c^{(i)} \log \left( f(\psi * \mathbf{x}^{(i)}; \Theta)_c \right), \quad (3)$$

donde  $\psi$  es el vector *máscara*.

La idea de saliency es similar a la que se utiliza para actualizar los pesos  $\Theta$ , calculando su derivada con respecto a la función de coste, esto es

$$\Theta \leftarrow \Theta - \alpha \frac{\partial \ell}{\partial \Theta}, \quad (4)$$

siendo  $\alpha$  el factor de aprendizaje.

En cuanto a su significado numérico, los valores altos en magnitud de la derivada indican que dicho peso está influyendo negativamente en el funcionamiento correcto del sistema, mientras que valores cercanos a 0 indican que el peso está bien ajustado. En el caso del saliency, nos interesaría que las



características con magnitudes altas sean las que contienen información más significativa, mientras que las cercanas a 0 sean características irrelevantes. Nuestra función de saliency se define como

$$\sigma(\mathbf{x}^{(i)}; \Theta, f, y^{(i)}) = \left| \frac{\partial g(\mathbf{x}^{(i)}; \Theta, f, y^{(i)})}{\partial \mathbf{x}^{(i)}} \right|, \quad (5)$$

esto es, nos interesa saber el gradiente de los ejemplos de entrada con respecto a una función, que llamaremos *función de ganancia* ( $g$ ), que devuelve su valor máximo cuando la clasificación es perfecta ( $\ell = 0$ ), y valores cercanos a 0 cuando el clasificador falla. En el caso de la función de coste de entropía cruzada que estamos utilizando (Eq. 2), definimos la función de ganancia como

$$g(\mathbf{x}^{(i)}; \Theta, f, y^{(i)}) = -\beta y^{(i)} \log(1 - f(\mathbf{x}^{(i)}; \Theta)), \quad (6)$$

donde  $\beta$  es un hiperparámetro que controla el decaimiento de la función de ganancia. Por defecto,  $\beta = 1$ . Para evitar un gradiente infinito, podemos aquellos valores de  $f(\mathbf{x}^{(i)}; \Theta) = 1$ . Por defecto,

$$f(\mathbf{x}^{(i)}; \Theta) = \min\{1 - e^{-8}, f(\mathbf{x}^{(i)}; \Theta)\} \quad (7)$$

Es importante remarcar que esta técnica es similar a la propuesta en [2]. Se diferencia en un único punto: mientras que el método en [2] es específico para un problema de clasificación, dado que descomponen la última capa de la red para aplicar su idea, nuestro modelo opera directamente como una función matemática de ganancia, lo que lo hace susceptible de poder ser utilizado en otro tipo de problemáticas, como los modelos de regresión. Otra ventaja de nuestra aproximación es que, dado que se aplica sobre una función de ganancia del clasificador, el gradiente es cercano a 0 cuando el clasificador se equivoca. Por tanto, el sistema nos dice que no hay características relevantes, haciéndolo robusto ante ejemplos que no son clasificados correctamente por la red.

### III. SELECCIÓN DE CARACTERÍSTICAS USANDO SALIENCY

Nuestro método de selección de características tendrá un comportamiento de tipo *ranker*, es decir, devolverá un vector ordenado de todas las características en función de su importancia. El esquema de nuestra aproximación puede verse en el Algoritmo 1.

El algoritmo propuesto tiene dos hiper-parámetros:  $\epsilon \geq 0$ , como control de parada, y  $1 \geq \gamma > 0$ , que controla el porcentaje de características *vivas* que van a ser mantenidas para la siguiente iteración.

Comenzamos entrenando la red neuronal  $f$  con todos los datos de entrenamiento. Luego, por cada clase calculamos el saliency de cada uno de los ejemplos, para luego normalizar mediante la norma 1. De esta manera para cada clase tenemos la probabilidad de que cada una de las características sea relevante para la clasificación. Una vez obtenidas las probabilidades de todas las clases, se suman y se ordenan, obteniendo el ranking de importancia de las características.

**Datos:**  $\mathbf{X}, \mathbf{Y}, f, \ell, \Theta, \gamma, \epsilon, reps$

**Resultado:** ranking de características  $\mathbf{r}$

$n_f \leftarrow R;$

$\mathbf{r} \leftarrow [1 \dots n_f];$

**mientras**  $n_f > \epsilon > 1$  **hacer**

$\hat{\mathbf{X}} \leftarrow \mathbf{X};$

$\hat{\mathbf{X}}[:, \mathbf{r}[n_f + 1 : R]] \leftarrow 0;$

$\sigma_{fs} \leftarrow \text{zeros}(n_f);$

**para**  $r \leftarrow 1$  **a**  $reps$  **hacer**

        Inicializar  $f(\hat{\mathbf{X}}; \Theta);$

        Entrenar  $f(\hat{\mathbf{X}}; \Theta)$  dado  $\mathbf{Y};$

**para**  $c \leftarrow 1$  **a**  $C$  **hacer**

$\sigma_c \leftarrow \sum_{i_c=1}^{N_c} \sigma(\mathbf{x}^{(i_c)}; \ell, \Theta, f, y^{(i_c)});$

$\sigma_{fs} \leftarrow \sigma_{fs} + \frac{\sigma_c}{\|\sigma_c\|_1};$

**fin**

**fin**

$\text{index} \leftarrow \text{argsort}(\sigma_{fs}, \text{descend});$

$\mathbf{r}[1 : n_f] \leftarrow \mathbf{r}[\text{index}];$

$n_f \leftarrow \text{int}(n_f * \gamma);$

**fin**

**Algoritmo 1:** Selección de características usando saliency

No obstante, hay que tener en cuenta que las redes neuronales son propensas al *sobre-entrenamiento* (overfitting). Esto haría que, en caso de que se eliminaran ciertas características, el reentrenamiento de la red cambiaría sustancialmente los valores de los pesos de la misma. Por esta razón, utilizaremos dos variables: (a) *reps*, que entrenará la red un número determinado de veces, para evitar valores atípicos; y (b), una vez obtenido el ranking de características, utilizamos el hiperparámetro  $\gamma$  para eliminar un porcentaje de las características, con objeto de volver a reentrenar la red y ajustar el orden de las características aún activas. El algoritmo se detendrá cuando el número de características activas sea inferior al hiperparámetro  $\epsilon$ .

Por lo tanto, la complejidad del algoritmo es variable, pues depende completamente del parámetro  $\gamma$ . En los casos extremos, tenemos que si  $\gamma = 0$ , entonces la complejidad es lineal ( $\mathcal{O}(Nreps)$ ), dependiendo sólo del número de ejemplos y de repeticiones. Sin embargo, con un  $\gamma \approx 1$ , la complejidad pasa a depender del número de variables ( $\mathcal{O}(RNreps)$ ), pues necesitamos entrenar tantas redes como características distintas tengamos.

### IV. RESULTADOS EXPERIMENTALES

Para evaluar el comportamiento de nuestra aproximación, hemos utilizado los 5 datasets propuestos en el *NIPS 2003 Features Selection challenge*<sup>1</sup>. Se trata de una serie de datasets sintéticos, diseñados con el objetivo de medir la calidad de los resultados obtenidos por los métodos de selección de características. Las características específicas de cada uno de estos datasets se muestran en la tabla I. Es un conjunto

<sup>1</sup><http://clopinet.com/isabelle/Projects/NIPS2003/>

Cuadro I  
DATASETS UTILIZADOS.

Conjunto	# ejemplos (entr., test)	# total características	# características válidas	% características válidas	ratio positivos/negativos
Arcene	(88, 112)	10000	7000	0.7	1.0
Dexter	(300, 300)	20000	9947	0.5	1.0
Dorothea	(800, 350)	100000	50000	0.5	0.11
Gisette	(6000, 1000)	5000	2500	0.5	1.0
Madelon	(2000, 600)	500	20	0.04	1.0

de datasets particularmente complejo porque incluye diversos tipos de casuísticas: pocos ejemplos de entrenamiento (Arcene), datos desbalanceados (Dorothea) o pocas características válidas (Madelon).

El algoritmo propuesto tiene la ventaja de que es capaz de calcular el ranking de las características al mismo tiempo que entrena el clasificador. Por tanto, se podría pensar que el subconjunto de características seleccionado es dependiente de la arquitectura. Por este motivo, hemos decidido separar la obtención de características del entrenamiento de la red, usando dos arquitecturas distintas para cada cometido. Con este punto creemos poder realizar una comparación más justa con otros métodos que no poseen esta característica, como son los basados en el análisis de información mutua [8].

*IV-0a. Arquitectura para la obtención del ranking de características:* Para este cometido hemos decidido utilizar una red neuronal totalmente conectada con 3 capas ocultas de 150, 100 y 50 elementos, respectivamente. Utilizamos *Batch Normalization* (BN) [9] seguido de la activación  $ReLU(x) = \max(0, x)$  en cada capa; como salida usamos un softmax, y utilizamos la entropía cruzada (Eq. 2) como función de coste.

Asimismo, usamos un *weight decay* de 0,001 para todos los pesos, con el objeto de eliminar el sobreentrenamiento. Entrenamos dicha red para un total de 100 iteraciones sobre el conjunto de entrenamiento, usando Adam [10] como optimizador. En el caso de tener datos desbalanceados, aumentamos el número de muestras hasta igualar los ejemplos disponibles para cada clase.

Para la creación y entrenamiento de esta red se ha utilizado el framework Keras <sup>2</sup> sobre Tensorflow [11].

*IV-0b. Arquitectura del clasificador:* Dado el pequeño número de muestras que tenemos en los conjuntos, nos hemos decantado por utilizar como clasificador una *Máquina de vector soporte* (SVM) con kernel gaussiano (RBF). Hemos usado el hiper-parámetro  $C = 1$ , sobre la implementación existente en la librería *scikit-learn* de Python.

#### IV-A. Efecto del parámetro $\gamma$

En primer lugar queremos conocer cuál es el efecto que producen los hiper-parámetros  $\gamma$  y *reps* (ver sección III y algoritmo 1). En el caso del parámetro  $\gamma$ , hemos ejecutado nuestro algoritmo utilizando para ello sólo una repetición para cada conjunto de características (*reps* = 1). En la Fig. 2 podemos observar cómo la precisión del algoritmo mejora conforme vamos aumentando el valor de  $\gamma$ . Esto es debido a que, dado

que el número de ejemplos de cada dataset es reducido, se produce mucho sobre-entrenamiento en la red. Dicho sobre-entrenamiento causa que determinadas características pasen a ser relevantes, únicamente debido a la inicialización del modelo.

Como caso inusual, en el dataset *Dorothea* se produce el efecto contrario. Esto puede ser debido tanto a la naturaleza de las características (binarias) del dataset, como a lo desbalanceado de los datos (muchos más ejemplos negativos que positivos).

#### IV-B. Efecto del parámetro *reps*

Como comentamos anteriormente, el sobre-entrenamiento introduce una variabilidad indeseada en la valoración de las características. Así como el uso del hiper-parámetro  $\gamma$  es una manera de tratar de solventar este inconveniente, éste también podría ser mitigado aumentando el número de veces que entrenamos la red, esto es, aumentando el parámetro *reps*.

Por tanto, hemos ejecutado nuestro algoritmo, fijando para ello el parámetro  $\gamma = 0$ , y variando el número de repeticiones. La Fig. 3 muestra los resultados obtenidos. Contrariamente a lo ocurrido con el hiper-parámetro  $\gamma$ , el aumento del número de repeticiones no conlleva una mejora sustancial de los resultados obtenidos. De igual manera, en el dataset *Dorothea* podemos ver que se produce el mismo efecto que ya habíamos presenciado con el hiper-parámetro  $\gamma$ .

#### IV-C. Evaluación de rendimiento

Para probar el rendimiento de nuestra propuesta, hemos decidido comparar nuestro método con una serie de algoritmos clásicos de selección de características: *MIM* [12] y *ReliefF* [13], en sus implementaciones existentes en la librería Weka [14]. Pese a que son algoritmos ya clásicos, siguen siendo utilizados en la actualidad por su probada eficacia. Los hemos escogido por ser métodos que devuelven un ranking de características, de la misma manera que lo hace nuestra propuesta. Además de estos algoritmos en Weka, hemos preparado también una variación del DeepLASSO [1] para poder usarlo en el estudio comparativo. El funcionamiento de éste es equivalente al de nuestro algoritmo, con la salvedad de que en lugar de una función de saliency, utilizaremos el valor absoluto de los valores de la máscara  $\gamma$  descrita en Eq. 3 como la medida de calidad de las características.

Como hemos mencionado anteriormente, hemos decidido separar la obtención del subconjunto de características relevantes del entrenamiento del clasificador, usando dos arquitecturas distintas para cada cometido. Con este punto creemos poder

<sup>2</sup><https://keras.io/>

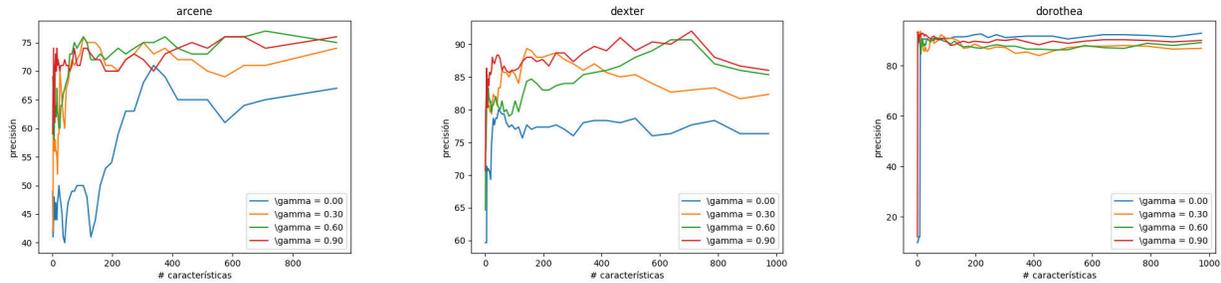


Figura 2. Efecto del hiper-parámetro  $\gamma$  sobre el algoritmo. Conforme su valor se acerca a 1, la selección de características se vuelve más precisa, especialmente cuando el número de características utilizadas es reducido.

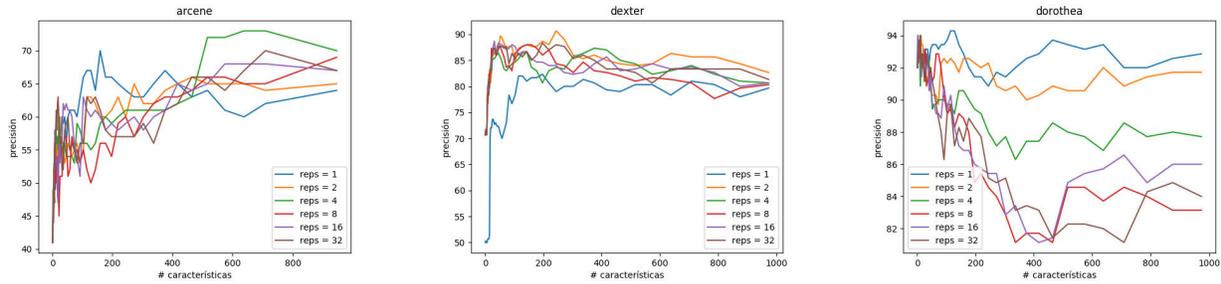


Figura 3. Efecto del hiper-parámetro  $reps$  sobre el algoritmo. Al contrario que con  $\gamma$ , su aumento no parece suponer una mejora significativa en los resultados.

realizar una comparación más justa contra los métodos *MIN* y *ReliefF*.

En la tabla II podemos observar los resultados obtenidos. En general, nuestra aproximación funciona de una manera análoga a los algoritmos basados en información mutua, algo remarcable dado que estamos utilizando dos arquitecturas distintas para el cálculo del ranking y la clasificación. Podemos observar como la técnica de DeepLASSO no obtiene buenos resultados cuando no utilizamos la misma arquitectura tanto para ranking como para la clasificación. Asimismo, también podemos observar como, en aquellos datasets que contienen más ejemplos (Gisette y Madelon), nuestro método es el que ofrece los mejores resultados. Asimismo, el valor del parámetro *Área bajo la curva* (AUC) de nuestra propuesta es mayor en prácticamente todos los conjuntos, lo que sugiere una robustez mayor en la selección de características.

Analizando un ranking de las posiciones medias en las que se situarían los cuatro métodos comparados, veríamos que nuestra propuesta es el que tiene mejor media en cuanto a precisión, con un puesto 1,6 de media entre los cuatro métodos, y es además es el segundo de los métodos, a muy poca diferencia de DeepLasso, que consigue mejores resultados con un subconjunto de características seleccionado más bajo (véase la tabla III). Nótese que la diferencia es bastante importante en conjuntos como Dexter, en los que consigue la segunda mejor precisión (con una diferencia de 0,04, pero con 28 características en vez de las 103 del mejor método en precisión, que en este caso es MIM). Así pues nuestra propuesta es bastante estable, consiguiendo los mejores resultados de precisión en media, con un número de características bajo.

## V. CONCLUSIONES Y TRABAJO FUTURO

En este paper hemos propuesto un nuevo algoritmo de selección de características basado en *saliency*. Dado un clasificador, y la creación de una función de ganancia, es posible conocer, para cada ejemplo, cuáles son las características más importantes a la hora de clasificar su comportamiento. Esta propiedad, por sí sola, añade una capacidad a nuestro algoritmo de la que carecen los métodos clásicos de selección de características. Asimismo, se trata de un método muy flexible, puesto que permite su uso en casi cualquier clasificador usado en la actualidad (SVM, CNN, ...). Por tanto, se trata de una herramienta muy útil para la selección de características en entornos de Big Data.

Como trabajo futuro, planteamos dos alternativas diferentes. En primer lugar, probar nuestro algoritmo con Big Data, especialmente con CNNs y datasets mucho más grandes, con objeto de confirmar los resultados obtenidos en este paper. Es de esperar que los resultados sean aún mejores, dado que el entrenamiento de la red sería aún más preciso. En segundo lugar, planteamos la modificación del Algoritmo 1, probando distintas configuraciones para el cálculo de  $\sigma_{fs}$ , tales como el uso de técnicas de ranking, o la eliminación de normalizaciones.

## REFERENCIAS

- [1] Y. Li, C.-Y. Chen y W. W. Wasserman, "Deep feature selection: theory and application to identify enhancers and promoters", *Journal of Computational Biology*, vol. 23, n.º 5, págs. 322-336, 2016.

Cuadro II

RESULTADOS OBTENIDOS. DADO QUE LOS DATASETS CONTIENEN CARACTERÍSTICAS ARTIFICIALES, SÓLO EVALUAMOS SU RENDIMIENTO HASTA UN NÚMERO DE CARACTERÍSTICAS, COMO MÁXIMO, IGUAL AL NÚMERO DE CARACTERÍSTICAS REALES (VÁLIDAS) DE CADA DATASET.

Conjto.	# carac. válidas	Método	Mejor Precisión (N° carac.)	Prec. 10 % carac. válidas	Prec. 25 % carac. válidas	Prec. 50 % carac. válidas	Prec. 100 % carac. válidas	AUC
Arcene	7000	MIM	81.0 (337)	75.0	74.0	74.0	73.0	0.736
		ReliefF	<b>83.0</b> (375)	<b>77.8</b>	<b>80.0</b>	<b>80.0</b>	71.0	<b>0.786</b>
		DeepLASSO	80.0 (464)	73.0	69.0	71.0	70.0	0.709
		Propuesta	81.0 (464)	76.0	72.0	77.0	<b>80.0</b>	0.773
Dexter	9947	MIM	<b>90.7</b> (103)	73.3	59.3	51.3	50.0	0.567
		ReliefF	86.0 (1204)	<b>85.0</b>	59.7	49.7	50.0	0.569
		DeepLASSO	87.3 (9)	62.3	53.0	49.7	50.0	0.533
		Propuesta	90.3 (28)	83.7	<b>77.0</b>	<b>72.0</b>	<b>52.0</b>	<b>0.732</b>
Dorothea	2500	MIM	94.3 (5)	88.0	81.7	63.1	<b>90.6</b>	0.794
		ReliefF	<b>94.6</b> (876)	<b>92.9</b>	<b>92.0</b>	23.4	<b>90.6</b>	0.682
		DeepLASSO	94.3 (5)	37.7	90.9	<b>90.3</b>	90.3	0.765
		Propuesta	94.3 (3)	90.9	89.7	88.9	89.1	<b>0.895</b>
Gisette	2500	MIM	98.4 (689)	97.0	98.1	<b>98.4</b>	97.9	0.978
		ReliefF	98.4 (1226)	97.7	98.0	<b>98.4</b>	<b>98.3</b>	0.980
		DeepLASSO	97.4 (82)	96.1	96.0	95.9	97.3	0.964
		Propuesta	<b>98.5</b> (516)	<b>98.0</b>	<b>98.5</b>	98.1	<b>98.3</b>	<b>0.981</b>
Madelon	2500	MIM	84.8 (13)	<b>67.8</b>	72.7	80.7	78.7	0.777
		ReliefF	85.3 (19)	62.7	61.8	80.7	<b>85.3</b>	0.754
		DeepLASSO	86.7 (6)	58.8	<b>86.0</b>	77.8	75.5	0.755
		Propuesta	<b>87.0</b> (6)	59.5	85.8	<b>86.2</b>	<b>85.3</b>	<b>0.828</b>

Cuadro III

RANKING DE LOS ALGORITMOS EN CUANTO A PRECISIÓN, Y EN CUANTO AL NÚMERO MÁS BAJO DE CARACTERÍSTICAS USADAS (ENTRE PARÉNTESIS)

Método	Posición Arcene	Pos. Dexter	Pos. Dorothea	Pos. Gisette	Pos. Madelon	Posición Media
ReliefF	1 (2)	4 (4)	2 (4)	2 (4)	3 (3)	2,4 (3,4)
Propuesta	2 (3)	2 (2)	2 (1)	1 (2)	1 (1)	<b>1,6</b> (1,8)
MIM	2 (1)	1 (3)	2 (3)	2 (3)	4 (2)	2,2 (2,4)
DeepLasso	3 (3)	3 (1)	2 (2)	3 (1)	2 (1)	2,6 ( <b>1,6</b> )

- [2] K. Simonyan, A. Vedaldi y A. Zisserman, “Deep inside convolutional networks: Visualising image classification models and saliency maps”, *arXiv preprint arXiv:1312.6034*, 2013.
- [3] A. Mahendran y A. Vedaldi, “Understanding deep image representations by inverting them”, en *Computer Vision and Pattern Recognition (CVPR), 2015 IEEE Conference on*, IEEE, 2015, págs. 5188-5196.
- [4] R. Zhao, W. Ouyang, H. Li y X. Wang, “Saliency detection by multi-context deep learning”, en *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, págs. 1265-1274.
- [5] D. Zhang, D. Meng y J. Han, “Co-saliency detection via a self-paced multiple-instance learning framework”, *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, n.º 5, págs. 865-878, 2017.
- [6] V. Mnih, N. Heess, A. Graves y col., “Recurrent models of visual attention”, en *Advances in neural information processing systems*, 2014, págs. 2204-2212.
- [7] K. Xu, J. Ba, R. Kiros, K. Cho, A. Courville, R. Salakhudinov, R. Zemel e Y. Bengio, “Show, attend and tell: Neural image caption generation with visual attention”, en *International Conference on Machine Learning*, 2015, págs. 2048-2057.
- [8] V. Bolón-Canedo, N. Sánchez-Marroño y A. Alonso-Betanzos, “A review of feature selection methods on synthetic data”, *Knowledge and information systems*, vol. 34, n.º 3, págs. 483-519, 2013.
- [9] S. Ioffe y C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift”, *arXiv preprint arXiv:1502.03167*, 2015.
- [10] D. P. Kingma y J. Ba, “Adam: A method for stochastic optimization”, *arXiv preprint arXiv:1412.6980*, 2014.
- [11] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard y col., “TensorFlow: A System for Large-Scale Machine Learning.”, en *OSDI*, vol. 16, 2016, págs. 265-283.
- [12] M. A. Hall y L. A. Smith, “Practical feature subset selection for machine learning”, 1998.
- [13] I. Kononenko, “Estimating attributes: analysis and extensions of RELIEF”, en *European conference on machine learning*, Springer, 1994, págs. 171-182.
- [14] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann e I. H. Witten, “The WEKA data mining software: an update”, *ACM SIGKDD explorations newsletter*, vol. 11, n.º 1, págs. 10-18, 2009.

**I Workshop de  
Grupos de Investigación  
Españoles de IA  
en Biomedicina  
(IABiomed 2018)**

JOSÉ M. JUAREZ  
MAR MARCOS  
DAVID RIAÑO





**I Workshop de  
Grupos de Investigación  
Españoles de IA  
en Biomedicina  
(IABiomed 2018)**

SESIÓN 1







# IASIS and BigMedilytics: Towards personalized medicine in Europe

Ernestina Menasalvas Ruiz, Alejandro Rodríguez González, Consuelo Gonzalo Martin  
*Centro de Tecnología Biomédica,*  
*ETS Ingenieros Informáticos,*  
*Universidad Politécnica de Madrid*  
 Pozuelo de Alarcón, Spain  
 {ernestina.menasalvas, alejandro.rg, consuelo.gonzalo}@upm.es

Massimiliano Zanin, Juan Manuel Tuñas  
*Centro de Tecnología Biomédica,*  
*Universidad Politécnica de Madrid*  
 Pozuelo de Alarcón, Spain  
 {massimiliano.zanin, juan.tunas}@ctb.upm.es

Mariano Provencio, Maria Torrente, Fabio Franco, Virginia Calvo, Beatriz Nuñez  
*Servicio de Oncología Médica,*  
*Hospital Universitario Puerta de Hierro*  
 Majadahonda, Spain

{mariano.provencio, maria.torrente}@salud.madrid.org, f3franc@gmail.com, vircalvo@hotmail.com, beangarcia@gmail.com

**Abstract**—One field of application of Big Data and Artificial Intelligence that is receiving increasing attention is the biomedical domain. The huge volume of data that is customary generated by hospitals and pharmaceutical companies all over the world could potentially enable a plethora of new applications. Yet, due to the complexity of such data, this comes at a high cost. We here review the activities of the research group composed by people of the Universidad Politécnica de Madrid and the Hospital Universitario Puerta de Hierro de Majadahonda, Spain; discuss their activities within two European projects, IASIS and BigMedilytics; and present some initial results.

**Index Terms**—Artificial Intelligence, Big Data, biomedical problems, Electronic Health Records, medical imaging

## I. INTRODUCTION

Since it was initially coined, the term Big Data is having an enormous impact in our society. It has gained such importance that governments around the world had to acknowledge its relevance in contexts such as politics, military, law, or management. Accordingly, the European Union followed this trend by creating specific associations and organizations dealing with the impact generated by Big Data and surrounding terms, such as Machine Learning, Artificial Intelligence, etc. If Big Data impacted several fields, the archetype is medicine, as it was soon understood that the incredible amount of routinely generated data could be used for very different purposes. Accordingly, the European Commission has launched several initiatives and calls aimed at funding projects with the objective of studying what are the insights that the extraction, analysis and use of medical data can provide.

The group of Minería de Datos y Simulación (MIDAS) (Data Mining and Simulation) of the Universidad Politécnica de Madrid (UPM) has followed very closely these movements. With more than 20 years of experience in applying Data Mining (DM) techniques to several fields, the current MIDAS team started several years ago to move its research area to the biomedical domain. Its technical expertise has been complemented by the collaboration with the medical oncology department of the Hospital Universitario Puerta de Hierro de Majadahonda (HUPHM), Madrid, Spain. This has resulted in the involvement in several projects in the context of Big Data and Artificial Intelligence in the medical field, with two of them funded by the European Commission.

This contribution aims at describing the MIDAS / HUPHM team, the expertise of their members, and the techniques by them used. A special focus is given to the two European projects in which they participate, with an analysis of their objectives and characteristics. Some of the results that have been obtained so far in these projects are also presented, as well as other related initiatives.

## II. THE TEAM

The meaningful application of Big Data techniques to the biomedical domain requires the convergence of two very different types of expertise: the knowledge of data managing and analysis on one hand and of the medical science on the other. This need buttressed the creation of collaboration between MIDAS and HUPHM, in which each partner contributes as described below.

### A. Universidad Politécnica de Madrid

The MIDAS group is responsible of tasks related with the extraction of knowledge from medical unstructured data, both in the form of text (electronic health records) and image (CT/PET images). The main people involved are:

- Ernestina Menasalvas Ruiz: Prof. Ernestina Menasalvas is a Full Professor at the “Escuela Técnica Superior de Ingenieros Informáticos” in UPM. She is the principal investigator of the projects described below, and is in charge of the global supervision as well as of tasks in the context of data understanding of text data and of the validation of the results.
- Consuelo Gonzalo Martin: Prof. Consuelo Gonzalo is an Associate Professor at “Escuela Técnica Superior de Ingenieros Informáticos” in UPM. She is the leader of the sub-team inside MIDAS involved in image processing, analysis and understanding. Her main activities include the coordination and supervision of all tasks related to information extraction and structuring, as well as knowledge generation from CT/PET images.
- Alejandro Rodríguez González: Prof. Alejandro Rodríguez is an Associate Professor at the “Escuela Técnica Superior de Ingenieros Informáticos” in UPM and the Principal Investigator of the Medical Data Analytics Laboratory at Center for Biomedical Technology (CTB). He supervises all efforts related to Natural Language Processing (NLP) tasks.
- Massimiliano Zanin: Dr. Massimiliano Zanin is a post-doctoral researcher at Center for Biomedical Technology at UPM. His main tasks include the supervision of the technical team developing the technical pipeline, and support the work of Prof. Rodríguez and Prof. Menasalvas.
- Juan Manuel Tuñas: D. Juan Manuel Tuñas is a researcher responsible for the analysis and post-processing of the NLP pipeline results.

### B. Hospital Universitario Puerta de Hierro-Majadahonda

Hospital Universitario Puerta de Hierro- Majadahonda is located in Madrid, Spain. This hospital, and more specifically, the medical oncology department, is in charge of providing the definition of the use cases and KPIs regarding the studied pathologies; the required data (electronic health records and images); and, more generally, the expertise necessary for the execution of the projects. The main people involved and their associated areas of responsibility are:

- Mariano Provencio: Medical Oncologist, Chief of Medical Oncology Department at Puerta de Hierro University Hospital, Full Professor, School of Medicine at Autónoma University of Madrid and Scientific Director of the Research Institute at Puerta de Hierro University Hospital. He is the principal investigator of the European projects described below, responsible for the Lung Cancer Pilot.
- Maria Torrente: Medical Doctor and PhD, responsible of international medicine programs in the Medical Oncology Department at Puerta de Hierro University Hospital.

Associate Professor, School of Medicine, Francisco de Vitoria University, Madrid. Coordinator of national and international research projects focused on clinical oncology.

- Fabio Franco: Medical oncologist and PhD, within the Lung cancer group in the Medical Oncology Department at Puerta de Hierro University Hospital.
- Virginia Calvo: Medical oncologist and PhD, within the Lung cancer group in the Medical Oncology Department at Puerta de Hierro University Hospital.
- Beatriz Nuñez: Medical oncologist and attending physician in the Medical Oncology Department at Puerta de Hierro University Hospital.

### III. THE PROJECTS

As previously introduced, the MIDAS / HUPHM group is participating in various projects applying Big Data and Artificial Intelligence to the medical domain. Two of them, both funded by the H2020 programme, are described below.

#### A. IASIS

Integration and analysis of heterogeneous big data for precision medicine and suggested treatments for different types of patients (IASIS)<sup>1</sup> is a Research and Innovation Action (RIA) funded by European Commission, within its H2020 programme, and under the call “*SC1-PM-18-2016 - Big Data supporting Public Health policies*”<sup>2</sup>. This call targeted projects dealing with the problem of acquiring, managing, sharing, modeling, processing and exploiting huge amount of data within the medical domain, with the goal of developing solutions to support public health authorities. Aligned with the goal defined in the call, IASIS project “*seeks to pave the way for precision medicine approaches by utilizing insights from patient data. It aims to combine information from medical records, imaging databases and genomics data to enable more personalized diagnosis and treatment approaches in two disease areas - lung cancer and Alzheimer’s disease*”.

At the current stage of development, IASIS is primarily focusing in an application to lung cancer, being the one on the Alzheimer domain planned for the following months. For this reason, the detailed description of the project objectives is here focused on the lung cancer domain.

IASIS aims to provide answers that can be relevant and effective for the medical practitioners. The main aims regarding lung cancer include:

- Obtaining descriptive and predictive patterns to improve overall survival.
- Early detection of relapse and early palliative care initiation, and reducing overtreatments, comparing retrospective datasets with new datasets obtained from our EHR System.
- Implementation of algorithms that reduce drug-drug interactions.

<sup>1</sup><http://project-iasis.eu/>

<sup>2</sup>[https://cordis.europa.eu/programme/rcn/700320\\_en.html](https://cordis.europa.eu/programme/rcn/700320_en.html)



- Risk stratification of lung cancer patients (treatment selection based on comorbidity index, family history, risk factors.).

In this context, the main use cases that have been defined in the lung cancer domain include:

- Identifying specific patterns in long surviving lung cancer patients, analysing all the key factors found that may associate to long survival, and compare long-survivors with the rest of the patients, in order to look for specific patterns (natural and family history, treatments, response to treatments, toxicities, comorbidities and molecular mechanisms).
- Search for risk and predictive factors for lung cancer in the study population.
- Analyse the effectiveness of tyrosin-kinase inhibitors (TKI) in mutated lung cancer patients (EGFR, ALKt, ROS-1), and look for a possible correlation between toxicities and type/duration of the TKI treatment.

The Project is coordinated by National Centre for Scientific Research “Demokritos” (NCSR) in Greece. Beyond UPM and HUPHM, additional partners include: the St. George’s Hospital Medical School (UK); Alzheimer’s Research (UK); Grupo español de investigación en cáncer de pulmón (Spain); the Centro de Regulación Genómica (CRG) (Spain); the university system of Maryland foundation (USA); and the Gottfried Wilhelm Leibniz Universitaet Hannover (Germany).

### B. BigMedilytics

Big Data for Medical Analytics (BigMedilytics) is an Innovation Action (IA) funded by European Commission, within its H2020 programme, and under the call “*Leadership in enabling and industrial technologies - Information and Communication Technologies (ICT)*”<sup>3</sup>. The projects funded under this call are also known as large-scale pilot projects. The aim of such initiative, in line with the flagship initiative ‘Digital Agenda for Europe’, includes “*enable[ing] Europe to support, develop and exploit the opportunities brought by ICT progress for the benefits of its citizens, businesses and scientific communities.*”

BigMedilytics goals include “*the transformation of Europe’s Healthcare sector by using state-of-the-art Big Data technologies to achieve breakthrough productivity in the sector by reducing cost, improving patient outcomes and delivering better access to healthcare facilities simultaneously, covering the entire Healthcare Continuum - from Prevention to Diagnosis, Treatment and Home Care throughout Europe.*” BigMedilytics is coordinated by Philips (Netherlands) and the consortium is composed of 35 partners from 11 different countries. Due to the size of the project and the consortium, its organization is divided in several pilots, focusing on the following medical areas/diseases: comorbidities, kidney disease, diabetes, asthma/COPD, heart failure, prostate cancer, lung cancer, breast cancer, stroke, sepsis, asset management workflows and radiology workflows.

<sup>3</sup>[https://www.cordis.europa.eu/programme/rcn/664147\\_en.html](https://www.cordis.europa.eu/programme/rcn/664147_en.html)

As in the IASIS project, the UPM / HUPHM team is working in the lung cancer pilot. The aim and KPIs defined in this pilot differ from the IASIS project as in IASIS we are more focused in the disease and finding answers to clinical questions that may help us improve our daily clinical practice, while Bigmedilytics is focused in optimizing not only the patient’s management, but also the medical oncology department’s workflow by:

- Increase of early diagnosis: identification of patients at risk of developing lung cancer.
- Reducing the cost per patient (reduction of visits to ER, readmissions, reduction of toxicities).
- Reducing toxicity rates specially in complex patients.
- Improving the patients satisfaction: increasing patient’s empowerment and information.

The additional partners involved in the lung cancer pilot of the BigMedilytics project include the National Centre for Scientific Research “Demokritos” (Greece), and the Gottfried Wilhelm Leibniz Universitaet Hannover (Germany).

## IV. DATA SOURCES

The main dataset used in both projects is provided by HUPHM to UPM and includes an anonymized dataset containing data from the Electronic Health Records of 700 lung cancer patients (171.891 clinical notes and 7.021 clinical reports).

### A. IASIS

The IASIS’ lung cancer disease area involves the analysis of two different types of unstructured data:

**Text:** The text in the IASIS project came from the Electronic Health Records (EHR) provided by HUPHM, describing patients diagnosed with lung cancer.

**Image:** A basic set of images has been provided by HUPHM, for patients with nodules diagnosed as malignity/non-malignity - in a further step, the analysis will be extended to different kinds of malignity. In addition to this, several open access image data bases have been used, including the Lung Image Database Consortium image collection (LIDC-IDRI<sup>4</sup>), NSCLS-Radiomics<sup>5</sup>, and LUNA<sup>6</sup>.

### B. BigMedilytics

In a similar manner, the lung cancer pilot in BigMedilytics will be executed with similar data (electronic health records provided in IASIS will be also available in BigMedilytics). The main differences in terms of data in BigMedilytics include:

- Image data are not provided: the analysis of the lung cancer information in BigMedilytics is not focused on the analysis of medical images.
- New structured data are provided, based on the specific goals and KPIs of the project:

- 1) Oncology calls: The HUPHM provided a set of files containing information about a service for the

<sup>4</sup><https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI>

<sup>5</sup><https://wiki.cancerimagingarchive.net/display/Public/NSCLC-Radiomics>

<sup>6</sup><https://luna.grand-challenge.org>

telephonic attention of cancer patients. This service is not exclusively focused on lung cancer patients. The data recorded contain information about the number of calls performed by each patient and their dates, reasons, and related information.

- 2) Oncology app: HUPHM developed a mobile application<sup>7</sup> with the aim of providing cancer patients with information and personalized advices about their disease.

## V. TECHNICAL WORK

As previously explained, both projects (IASIS and BigMedilytics) deal with three types of data:

- Textual information (Electronic Health Records),
- Medical images, and
- Structured data (Call service and mobile app).

For a better understanding of the main technological goals, the methodology associated to each one of these types is described below.

### A. Textual information

The main goal of UPM in this project in terms of the textual information implies:

- To analyze structure free text. UPM is developing a framework called CliKES (Clinical Knowledge Extraction System) based on the Apache UIMA infrastructure. The system is in charge of performing most of the tasks of the classical NLP pipeline, starting with the clinical notes and reports of the patients' EHRs, to end up with a database containing all relevant information. The novelty behind the current work is based on the application of NLP techniques to EHR in Spanish, along with the creation of ad-hoc annotators focused on identifying terms referred to lung cancer domain (including treatments, mutations, etc.).
- To analyze the structured data yielded by the CliKES pipeline, to synthesize useful information for the physicians according to the use cases definition. Specifically, physicians aim at getting relevant information about possible co-occurrences in their lung cancer patients, as well as at trying to find specific correlations between them.
- To provide the results to the IASIS and BigMedilytics consortium, more specifically to the Hannover team, for the creation of knowledge graphs with the information of those patients. Both projects aim at creating a semantic-based version of the data, to allow complex queries with the processed patient data, medical literature knowledge provided by NCSR, and genetic information (in IASIS only, provided by CRG).

### B. Medical images

- Structuring image data. Two types of features have been extracted from the available images: semantic and agnostic features. A python script module has been developed

to extract the former ones from CT images in DICOM format. The principal tool used in this module has been Py-Radiomics [1], but also other proprietary libraries. Pre-trained Convolutional Neural Networks (CNN) models have been used for the extraction of agnostic features [3]. The most usual approach of feeding these models is by means of a sliding cube through the 3-D images; yet, this was here completely unviable from a computational point of view. In order to drastically reduce the volume of data to be processed, while minimizing the loss of information, this process has been implemented at a supervoxel level [2].

- In a future phase, the features extracted from images will be used to generate models allowing yielding useful knowledge for physician, such as predicting the survival time of lung cancer patients.
- Finally, provide the results to the IASIS consortium, more specifically to Hannover team, for the creation of knowledge graphs with the information of those patients.

### C. Structured data

Two specific data sources were part of BigMedilytics' lung cancer: HUPHM Oncology call service and OncoApp mobile application. The aim of UPM is to integrate the data generated by these services (which is already in a structured form) to improve the analysis that will be performed; more specifically, to find correlations and patterns in the patients based on their clinical information and their behavior in using these services.

## VI. CONCLUSIONS

As has been shown for all the types of data explained in this paper, a clear relationship is present between the aim of these projects and the application of Artificial Intelligence and Machine Learning techniques. On one hand, both projects have to deal with unstructured data (in image or text form), which require the application of complex techniques and strategies for their handling. In the case of text data, UPM is researching and developing a tool named CliKES, aimed at processing Electronic Health Records in Spanish, something that although has been under development and research by several groups in Spain, is still an on-going task. The nature of the data provided by each hospital and the corresponding processing, the problems associated to the narratives written by each physician, the identification of events, the detection of negation or acronyms in the correct context, the recognition of entities and the appropriate identification of information and the subject that belong to are, among other problems, still open problems in the field of Natural Language Processing, and this despite the large amount of work in the field. Here it is important to emphasize how the machine learning techniques play a very important role in several of the tasks of the NLP pipeline, and how important is to find accurate models to create accurate NLP systems.

Finally, both projects have to deal with structured data. In this context, UPM is mainly working on the application of Data Mining techniques to find important insights and

<sup>7</sup><https://play.google.com/store/apps/details?id=org.idiphim.oncoapp>



evidences within the data. The amount of data, as well as its diversity (textual, image, call service, mobile application), requires huge efforts in terms of structuring, processing and cleaning. These efforts are done with the objective of having data with enough quality, to subsequently apply the correct data mining techniques and finding evidences based on the use cases, these latter defined by the physicians as well as the associated KPIs.

A comprehensive characterization of lung cancer tumor signatures is critical for a correct diagnosis and optimal treatments. As precision medicine is practiced more widely, one of the main challenges is the integration and analysis of clinical data, opening new opportunities for more accurate diagnosis, more sensitive and frequent disease monitoring and more personalized therapeutic strategies, at the level of the individual.

#### ACKNOWLEDGMENT

This paper is supported by European Union's Horizon 2020 research and innovation programme under grant agreement No. 727658, project IASIS (Integration and analysis of heterogeneous big data for precision medicine and suggested treatments for different types of patients) and by the European Union's Horizon 2020 innovation programme under grant agreement No. 780495, project BigMedilytics (Big Data for Medical Analytics).

#### REFERENCES

- [1] J.J. Van Griethuysen, A. Fedorov, C. Parmar, N. Aucoin, V. Narayan, R.G.H. Beets-Tan, J.-C. Fillion-Robin, S. Pieper, and H.J.W.L. Aerts, "Computational Radiomics System to Decode the Radiographic Phenotype", *Cancer Res.*, vol. 77, pp. e104–e107, November 2017.
- [2] C. Gonzalo-Martín, A. García-Pedrero, M. Lillo-Saavedra and E. Menasalvasa, "Deep Learning for Superpixel-Based Classification of Remote Sensing Images", *GEOBIA 2016: Solutions and Synergies*, 2016.
- [3] K.H. Cha, L. Hadjiiski, R.K. Samala, H. Chan, E.M. Caoili, and R.H. Cohan, "Urinary bladder segmentation in CT urography using deep-learning convolutional neural network and level sets", *Med. Phys.*, vol. 43, pp. 1882–1896, 2016.



# Tecnologías para el Modelado, Procesamiento y Gestión de Conocimiento

Jesualdo Tomás Fernández Breis  
*Universidad de Murcia, IMIB-Arrixaca*  
Murcia, España  
jfernand@um.es

Marcos Menárguez Tortosa  
*Universidad de Murcia, IMIB-Arrixaca*  
Murcia, España  
marcos@um.es

Catalina Martínez Costa  
*Medical Graz University*  
Graz, Austria  
catalina.martinez@medunigraz.at

José Antonio Miñarro Giménez  
*Medical Graz University*  
Graz, Austria  
jose.minarro-gimenez@medunigraz.at

María del Carmen Legaz García  
*FFIS, IMIB-Arrixaca*  
Murcia, España  
mcarmen.legaz@ffis.es

Manuel Quesada Martínez  
*Universidad Miguel Hernández*  
Elche, España  
mquesada@umh.es

Astrid Duque Ramos  
*Universidad de Antioquia*  
Medellín, Colombia  
astrid.duquer@udea.edu.co

Ángel Esteban Gil  
*FFIS, IMIB-Arrixaca*  
Murcia, España  
angel.esteban@ffis.es

Dagoberto Castellanos Nieves  
*Universidad de La Laguna*  
Tenerife, España  
dcastell@ull.es

**Abstract**—El grupo de investigación *Tecnologías para el Modelado, Procesamiento y Gestión de Conocimiento* lleva quince años investigando, desarrollando y aplicando tecnologías semánticas en dominios biomédicos. En este trabajo se describen las líneas de investigación más relevantes en las que hemos trabajado en los últimos años, y cuyo objetivo principal es la consecución de interoperabilidad semántica entre sistemas de información sanitarios. Asimismo, también se comentarán objetivos de investigación para los próximos años en los que las técnicas inteligentes desempeñarán un papel importante.

**Index Terms**—Artificial Intelligence, Knowledge Engineering, Electronic Medical Records

## I. PRESENTACIÓN DEL GRUPO DE INVESTIGACIÓN

El grupo *Tecnologías para el Modelado, Procesamiento y Gestión de Conocimiento* (TECNOMOD) se creó en la Universidad de Murcia en el año 2003 constituyendo la ingeniería ontológica, la web semántica y las tecnologías del lenguaje sus áreas principales de investigación. Actualmente el grupo de investigación tiene 15 integrantes (profesores, becarios y contratados), y cuenta con colaboradores a nivel nacional e internacional, incluyendo antiguos doctorandos del grupo cuya contribución a los resultados que se presentan en este trabajo ha sido fundamental. La mayoría de los integrantes del grupo de investigación son informáticos, si bien disponemos de dos investigadores cuya formación y actividad es sanitaria y un biotecnólogo. Hemos aplicado nuestra investigación en diversos dominios como el turismo, las finanzas, la política o la educación, pero la biomedicina ha sido el área donde más investigación hemos realizado. En este documento nos ceñiremos a la investigación realizada exclusivamente en este ámbito, y especialmente destacaremos dos líneas: interoperabilidad semántica y aseguramiento de la calidad de ontologías y terminologías biomédicas.

TECNOMOD es miembro del Instituto Murciano de Investigación Biosanitaria (IMIB-Arrixaca), que está acreditado por el Instituto de Salud Carlos III. IMIB-Arrixaca está vinculado al Hospital Universitario Virgen de la Arrixaca. Tenemos colaboraciones en marcha con varios grupos de investigación del instituto y una colaboración permanente con la Plataforma de Informática Biomédica y Bioinformática del mismo.

## II. CONTEXTO

La Web Semántica [2] es un espacio natural para la integración de datos y la interoperabilidad semántica entre sistemas, imponiendo un entorno de trabajo en el que cada sistema emplea el significado de los datos en diferentes contextos [10]. Las tecnologías semánticas posibilitan la descripción del contexto lógico de la información a intercambiar, mientras que se permite que cada sistema mantenga su máxima independencia. Las ontologías constituyen el nivel fundamental de la Web Semántica desde el punto de vista de representación formal del conocimiento, de ahí que parte del éxito de la Web Semántica recaiga en la calidad de las ontologías, por lo que el desarrollo de métodos que permita asegurar la calidad de las mismas es un objetivo crítico para entornos de interoperabilidad. En los últimos años, las tecnologías de la Web Semántica han ganado popularidad para la consecución de interoperabilidad semántica entre sistemas de información sanitarios, especialmente desde que el proyecto Semantic Health [24] recomendó su uso para dichos fines. Posteriormente, la FP7 Network of Excellence SemanticHealthNet<sup>1</sup> propuso que la formalización ontológica debería ser fundamental para permitir el intercambio y la cooperación entre los sistemas de historia clínica

<sup>1</sup><http://www.semantichealthnet.eu>



electrónica (HCE) y los sistemas de ayuda a la decisión (SAD). Dicho rol de las ontologías en escenarios de interoperabilidad impone una serie de requisitos sobre las ontologías [8]:

- Facilitar la representación, compartición, reutilización de conocimiento para modelos de información y de inferencia.
- Clasificar y recuperar datos de HCE según las reglas establecidas en guías y protocolos.
- Tener garantizada su calidad formal y estructural.

En este trabajo agrupamos nuestras líneas de investigación en dos grupos:

- Interoperabilidad semántica en salud (Sección III): investigación orientada a conseguir el intercambio de información entre sistemas sanitarios, incluyendo HCE y SAD.
- Aseguramiento de calidad de ontologías (Sección IV): investigación orientada a evaluar el cumplimiento de los requisitos de interoperabilidad por parte de las ontologías y terminologías biomédicas.

La investigación que se describirá en las próximas secciones ha sido posible gracias a financiación fundamentalmente pública. A continuación se enumeran los proyectos más relevantes de los últimos diez años.

- **Plataforma para la adquisición y compartición de información y conocimiento para comunidades de investigación clínica en red II** (TSI2007-66575-C02-02). Ministerio de Educación y Ciencia. 01/10/2007-31/12/2010.
- **Herramientas inteligentes para enlazar historias clínicas electrónicas y sistemas de ensayos clínicos II** (TIN2010-21388-C02-02). Ministerio de Ciencia e Innovación. 01/01/2011-31/12/2014.
- **Modelos de información y conocimiento clínicos para enlazar los sistemas de historia clínica electrónica y de ayuda a la decisión clínica II** (TIN2014-53749-C2-2-R). Ministerio de Economía y Competitividad. 01/01/2015-31/12/2018.
- **Semantic Interoperability for Health Network**. Unión Europea. 03/10/2012-30/11/2014. Red de Excelencia del programa FP7 en la que miembros de TECNOMOD participaron como expertos externos en el paquete de trabajo 4 "Harmonised resources for EHR/PHR and aggregation".
- **Gene regulation ensemble effort for the knowledge commons** (CA COST Action CA15205). Unión Europea. 08/09/2016 - 07/09/2020. Participación de TECNOMOD como líder del paquete de trabajo de ontologías y vocabularios controlados.
- **Unraveling in utero determinants predicting lung function in infants: a step for prenatal prevention of asthma** (PIE15/00051). Instituto de Salud Carlos III. 01/01/2016-31/12/2018.
- **Infraestructura y tecnologías de interoperabilidad para aplicaciones de Learning Health Systems I**

(TIN2017-85949-C2-1-R). Ministerio de Economía, Industria y Competitividad. 01/01/2018 - 31/12/2020.

### III. INTEROPERABILIDAD SEMÁNTICA EN SALUD

#### A. Transformación de datos y modelos clínicos

Las recomendaciones del proyecto SemanticHealth incluyeron el uso combinado de estándares de historia clínica electrónica, ontologías y terminologías biomédicas para facilitar el intercambio significativo de datos. Nuestro grupo de investigación desarrolló PoseacleConverter<sup>2</sup> como demostrador de las posibilidades de intercambio de datos entre distintos formatos de modelos clínicos (openEHR, ISO 13606 o CEM) y de datos entre openEHR e ISO 13606.

El trabajo comenzó en el año 2008 y el primer objetivo fue la transformación de arquetipos (como tipo de modelo clínico) entre los estándares openEHR e ISO 13606 [14]. La transformación de modelos se basó en la formalización de correspondencias entre las ontologías que representaban los modelos de información de los estándares. Esto permitió definir unas reglas que guiaron la transformación estructural de los arquetipos. Este método se extendió para transformar datos entre dichos estándares explotando las correspondencias anteriores [13]. El uso de ontologías permitió también comprobar en ambos esfuerzos la consistencia lógica de los modelos y datos obtenidos mediante el uso de razonadores. La figura 1 describe el proceso seguido a nivel de datos. Se puede apreciar en la parte inferior el extracto de datos fuente ISO 13606, que es transformado en un extracto openEHR usando las correspondencias definidas a partir de las ontologías. Para la aplicación de la transformación de datos no es necesaria la existencia del arquetipo destino, el cual se crea automáticamente. Esto genera una traza de transformación que es empleada para la generación del extracto destino.

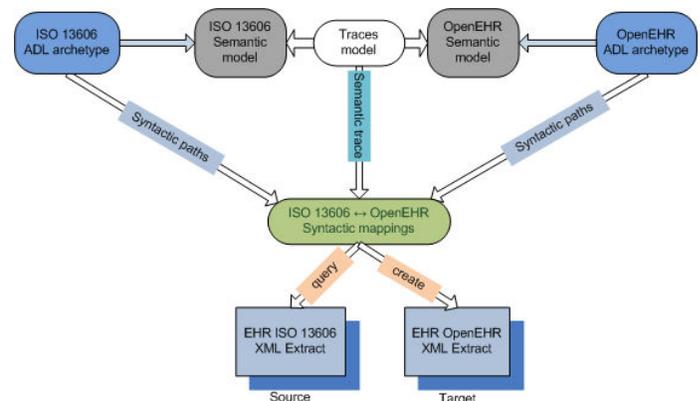


Fig. 1. Esquema de transformación de datos

Posteriormente el enfoque de transformación de modelos clínicos evolucionó cuando diseñamos el proceso para obtener arquetipos openEHR a partir de modelos clínicos CEM [11]. El nuevo enfoque se desarrolló exclusivamente con tecnologías OWL. En este caso las relaciones entre los modelos de

<sup>2</sup>miuras.inf.um.es/PoseacleConverter

referencia se expresaron como axiomas OWL y se crearon plantillas de transformación. De esta manera, la transformación se concibió como un proceso generativo de axiomas OWL, y el proceso estaba asistido por un razonador. La figura 2 ejemplifica este proceso de generación: (1) representación OWL del modelo clínico CEM; (2 y 3) plantillas de generación para los dos ítems incluidos en el modelo; (4) ontología del modelo de información openEHR, que se utiliza para la definición de las plantillas; (5, 6 y 7) representación parcial en OWL del modelo transformado a openEHR.

Estos métodos se evaluaron y validaron con las colecciones de arquetipos openEHR disponibles en CKM y modelos CEM disponibles en la librería de Intermountain disponibles en su momento.

### B. Validación semántica de arquetipos

El intercambio automático de datos a través de sistemas informáticos basado en modelos clínicos, como pueden ser los arquetipos, requiere la corrección formal de los mismos. Nuestro grupo de investigación desarrolló Archeck<sup>3</sup> [15], que un método basado en OWL para la validación de arquetipos. Los arquetipos son representados como clases OWL y la validación semántica de los mismos se realiza mediante el uso de razonadores automáticos. Para ello usa una ontología que define los tipos de restricciones que se pueden definir para un arquetipo y que vienen especificados en el modelo de arquetipos. Además, Archeck extiende esta ontología para poder definir métricas de calidad para arquetipos basadas en OWL. El método Archeck se aplicó a dos repositorios públicos de arquetipos openEHR, el repositorio gestionado en la herramienta Clinical Knowledge Manager (CKM) y el repositorio de programa National Health Service (NHS) del Reino Unido. La evaluación de los repositorios se centró en los arquetipos que definen relaciones de especialización, 81 en CKM y 212 en NHS. La validación de los repositorios encontró que un 22,2% de los arquetipos especializados en el repositorio CKM y un 21,2% en NHS contenían errores. De ellos, el 3% de los errores en CKM fueron identificados gracias a la métrica de calidad descrita anteriormente. Si bien puede considerarse un valor bajo esto también se debió a que los muchos de los arquetipos evaluados no contenían enlaces terminológicos, lo cual es un indicador negativo de calidad.

### C. Interoperabilidad de modelos de información, dominio e inferencia

El trabajo en esta línea es el fruto de proyectos coordinados con la Universidad Politécnica de Valencia (UPV) y la Universidad Jaime I (UJI). UPV es experto en modelos de información, UJI en modelos de inferencia y nuestro grupo en modelos de dominio. El trabajo realizado en esta línea pretende conseguir aplicar las guías clínicas computerizadas a datos estandarizados de la HCE. Para ello se presentan las ontologías como elemento mediador que proporcione la semántica compartida entre ambos modelos.

<sup>3</sup>[miuras.inf.um.es/archeck](http://miuras.inf.um.es/archeck)

1) *Flujos de transformaciones interoperables. Aplicación a la clasificación de pacientes:* El primer trabajo en esta línea afrontó cómo abordar problemas de clasificación de pacientes a partir de protocolos estandarizados mediante las tecnologías de estándares de HCE y las ontologías [7]. Esto determinó un flujo de trabajo cuya entrada son datos no normalizados de HCE y la salida es la clasificación del paciente, tal y como se puede ver en la figura 3. En este caso trabajamos también en colaboración con el Programa de cribado de cáncer de colon y recto de la Región de Murcia. El objetivo específico era determinar el nivel de riesgo de los pacientes del programa. Para ello trabajamos con las guías europea y americana de cáncer de colon y recto. Las tecnologías semánticas contribuyen en dos etapas del proceso, como son la representación de los datos en formato semántico y la clasificación del paciente usando razonadores. Para ello también fue necesario formalizar las reglas de los protocolos en OWL. Este trabajo se sigue desarrollando a través de la plataforma CLIN-IK-LINKS [12], que busca generalizar y facilitar la definición y ejecución de transformaciones de datos interoperables.

2) *Enriquecimiento de guías clínicas computerizadas:* Una línea reciente de trabajo busca formalizar el conocimiento de las guías clínicas computerizadas (GCC) con conceptos existentes en ontologías y terminologías biomédicas, trabajo que se está realizando con colaboración con la UJI. El primer trabajo realizado ha sido identificar los conceptos de ontologías de BioPortal a partir de un conjunto de GCC seleccionado y disponible en formato PROforma [9]. SNOMED CT fue el recurso semántico con mayor número de resultados, por lo que es la que estamos usando en los estudios y evaluaciones preliminares del método desarrollado [22]. La figura 4 muestra cómo procesamos la GCC. Una vez extraído el texto a procesar, se buscan alineamientos usando métodos basados en OntoEnrich (ver Sección IV-B). El resultado es un conjunto de recomendaciones de conceptos asociados a la guía clínica.

## IV. ASEGURAMIENTO DE CALIDAD DE TERMINOLOGÍAS Y ONTOLOGÍAS

### A. Evaluación de calidad de ontologías

OQuaRE<sup>4</sup> [5] es un *framework* para la evaluación de ontologías basado en la norma ISO/IEC 25000:2005 para la definición de requisitos y evaluación de la calidad de productos software, también conocida como SQuaRE [1]. OQuaRE realiza la evaluación de la calidad de ontologías con tres niveles de granularidad: características, subcaracterísticas y métricas de calidad. Actualmente el modelo de calidad de OQuaRE incluye 8 características, 29 subcaracterísticas y 19 métricas. Cada característica tiene un conjunto de subcaracterísticas asociadas que, a su vez, tienen asociadas un conjunto de métricas. Toda la información sobre el modelo de calidad está disponible en el sitio web de información sobre OQuaRE<sup>5</sup>.

Las métricas de OQuaRE tienen una función  $f(x)$  cuyo dominio es una ontología, pero el rango de cada métrica puede

<sup>4</sup><http://sele.inf.um.es/oquare>

<sup>5</sup><http://miuras.inf.um.es/oquarewiki>

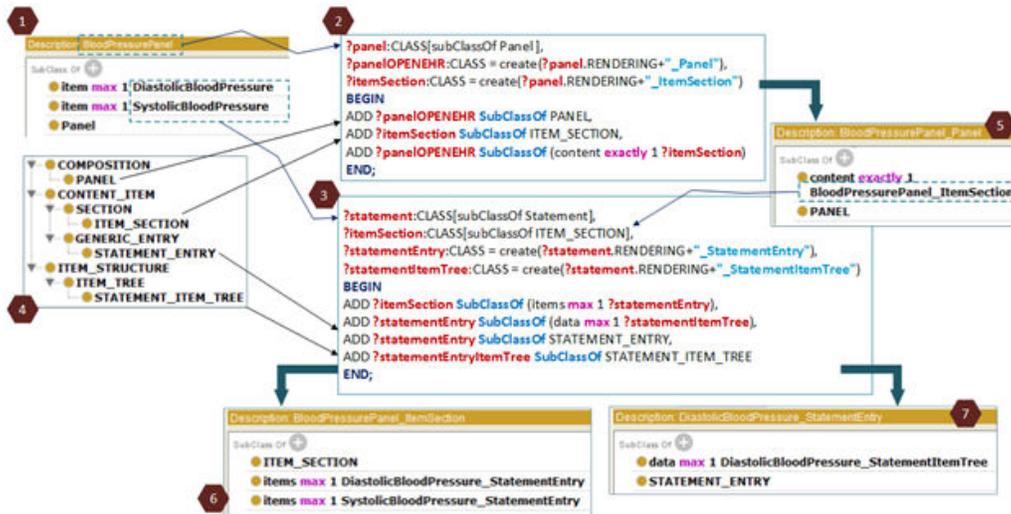


Fig. 2. Esquema de transformación de datos

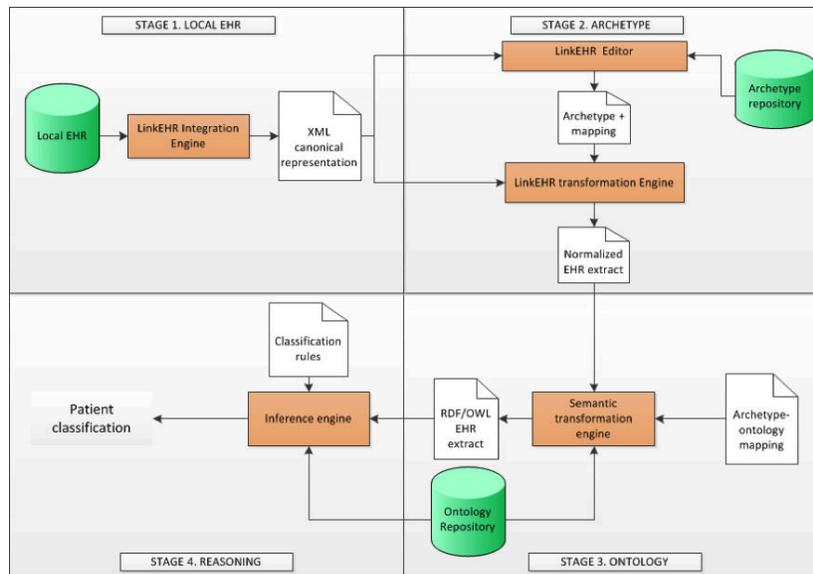


Fig. 3. Flujo de transformación de datos

variar. Tener una visión global de la evaluación de una ontología requiere combinar los resultados de todas las métricas. Es por ello que OQuARE define dos tipos de funciones de escalado de métricas, que permiten abstraer al método de los distintos rangos de cada métrica:

- **Estática**, basada en recomendaciones y buenas prácticas.  $n(f(x))$  está predefinida y está basada en intervalos fijos continuos que particionan el rango de  $f(x)$  en  $k$  categorías.
- **Dinámica**, que usa datos experimentales como referencia.  $n(f(x))$  aplica el método de clustering  $k$ -means para particionar el rango de  $f(x)$  en  $k$  intervalos continuos no prefijados que contienen todas las observaciones incluidas en los datos experimentales. Para maximizar la compactación de las ontologías de cada categoría, min-

imizando la varianza intra-cluster, y para maximizar la separación entre las categorías, maximizando la varianza inter-cluster en cada iteración se recalculan los nuevos  $k$  centroides y la asignación de cluster se realiza asociando cada  $R_{\theta_j}$  al centroide más cercano. El algoritmo de clustering requiere la información de si los valores altos de  $f(x)$  se corresponden con las categorías más altas del factor. Esto se debe a que valores altos de una métrica no tienen por qué representar siempre una buena propiedad de una ontología.

Además, cabe mencionar que la versión actual de OQuARE usa  $k = 5$  para todas las métricas. La escala estática de OQuARE ha sido aplicada para analizar ontologías [3], mientras que la dinámica ha sido empleada para estudiar la evolución de ontologías. Para ello se han usado como datos

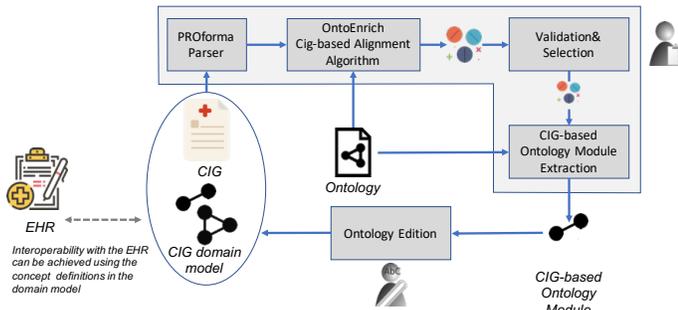


Fig. 4. Diagrama de procesamiento del contenido de la guía clínica computarizada

experimentales los valores de las métricas para cada versión de la ontología procesada [6], [17]. El conjunto de datos experimentales también puede estar compuesto por una versión de cada ontología, sirviendo entonces para medir similitudes y diferencias entre ellas.

### B. Enriquecimiento de ontologías

OntoEnrich <sup>6</sup> es un método para el enriquecimiento de ontologías biomédicas basada en el análisis léxico de sus etiquetas [16], ya que las ontologías son ricas en contenido léxico para humanos, el cual no se pone siempre a disposición de las máquinas en forma de axiomas lógicos. Por tanto, el objetivo principal de OntoEnrich es explotar la semántica oculta de las ontologías [25]. OntoEnrich se basa en el concepto de regularidad léxica (RL), que se define como un conjunto de tokens consecutivos repetidos en diferentes etiquetas de la ontología. Cabe mencionar que la entrada habitual a OntoEnrich es una ontología en formato OWL, si bien en distintos casos de uso la herramienta que implementa la metodología ha sido adaptada para aceptar otros tipos de entradas, como ficheros de texto donde cada línea incluya cada etiqueta a analizar. La figura 5 muestra las principales etapas de la metodología:

- **Procesamiento de la ontología y cálculo de regularidades léxicas.** En primer lugar permite obtener el conjunto completo de regularidades léxicas (RL) utilizando como parámetro de entrada un *threshold* mínimo que permite podar las búsquedas. También se establecen relaciones super-sub entre regularidades léxicas. Se realiza también una descripción cuantitativa de cada RL. Se buscan alineamientos a partir de las RD en la propia ontología o en otras externas para promover la reutilización de conceptos entre la comunidad biomédica, y estos algoritmos buscan clases que contengan la RL o cuya etiqueta coincida con la RL [21].
- **Cálculo de métricas avanzadas.** En esta etapa se calculan métricas avanzadas que relacionan las RL con diferentes aspectos semánticos de la ontología, como localización o modularidad de las RL y los productos

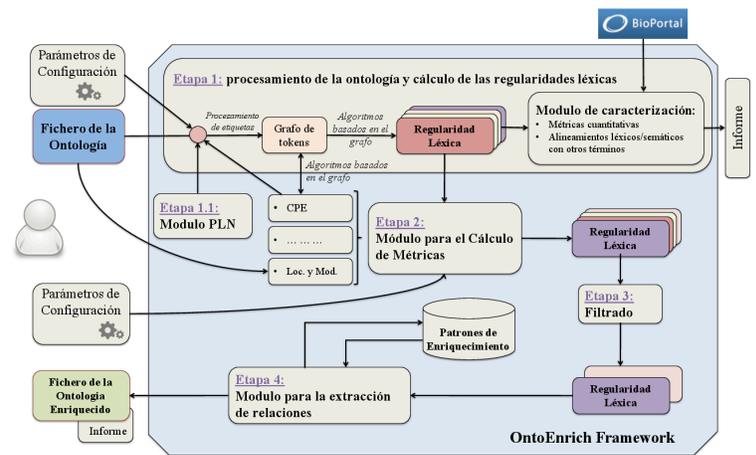


Fig. 5. Descripción de la metodología aplicada por OntoEnrich

crucados, que informa sobre la potencialidad de enriquecimiento de una RL.

- **Filtrado de regularidades.** OntoEnrich permite utilizar las métricas para definir filtros que reducen el conjunto de RL a aquellas que cumplen ciertas propiedades. Se podría filtrar a aquellas RL que poseyeran determinado valor de modularidad, localización, etc. También se pueden filtrar las subregularidades para quedarnos con las regularidades más largas, ya que esto quiere decir que son más específicas.
- **Extracción de relaciones y axiomas.** En este paso se permite la definición de patrones axiomáticos a partir de las RL anteriores. El método es capaz de crear automáticamente patrones a partir de relaciones de subclase. Como resultado de la ejecución de dichos patrones se obtendría la ontología enriquecida.

### C. Aplicaciones basadas en OQuARE y OntoEnrich

Los métodos OQuARE y OntoEnrich se han aplicado para analizar las ontologías de repositorios de ontologías biomédicas como OBO Foundry y BioPortal con el objeto de caracterizar dichas ontologías desde el punto de vista de optimalidad para su uso en escenarios de interoperabilidad. Los aspectos específicos que han contribuido a estudiar han sido:

- Evaluación de ontologías [4], [6], [17].
- Evaluación de la aplicación de principios de diseño de ontologías, como delineación de contenido, riqueza de relaciones y nombrado sistemático [20], [21].
- Análisis de reutilización de axiomas y axiomas ocultos en ontologías [18].
- Enriquecimiento de la Gene Ontology [23].
- Detección de axiomas potencialmente erróneos y detección de posibles axiomas en SNOMED CT [19], [26].

## V. PRÓXIMOS OBJETIVOS

En estas líneas de investigación pretendemos aplicar a corto plazo técnicas de inteligencia artificial para los siguientes

<sup>6</sup><http://sele.inf.um.es/ontoenrich>



objetivos:

- Desarrollar el concepto de *Learning Health Systems* incluyendo técnicas de machine learning dentro de los flujos de procesamiento de datos interoperables.
- Analizar ontologías a partir de conjuntos de datos de HCE.
- Extracción de módulos de ontologías para el enriquecimiento de guías clínicas computerizadas y de otras ontologías.
- Aprendizaje del valor óptimo de  $k$  para cada métrica empleada en OQuARE en la función de escalado dinámica.
- Clasificación y analizar tipos y grupos de ontologías a partir de los valores de sus métricas.
- Identificación de relaciones entre métricas de las ontologías y principios de diseño.
- Aprendizaje automático de patrones axiomáticos a partir de regularidades léxicas.

#### AGRADECIMIENTOS

Este trabajo ha sido posible gracias a la financiación del Ministerio de Educación y Ciencia (TSI2007-66575-C02-02), Ministerio de Ciencia e Innovación (TIN2010-21388-C02-02), Ministerio de Economía, Industria y Competitividad (TIN2014-53749-C2-2-R, TIN2017-85949-C2-1-R), así como el Fondo Europeo de Desarrollo Regional (FEDER) a través de los proyectos citados.

#### REFERENCIAS

- [1] ISO/IEC 25000:2005, Software Engineering - Software Product Quality Requirements and Evaluation (SQuaRE) - Guide to SQuaRE, 2005. [Online; accessed 01-June-2017].
- [2] T. Berners-Lee, J. Hendler, O. Lassila, et al. The semantic web. *Scientific american*, 284(5):28–37, 2001.
- [3] A. Duque-Ramos, M. Boeker, L. Jansen, S. Schulz, M. Iniesta, and J. T. Fernández-Breis. Evaluating the good ontology design guideline (goodod) with the ontology quality requirements and evaluation method and metrics (oquare). *PLOS ONE*, 9(8):1–14, 08 2014.
- [4] A. Duque-Ramos, J. T. Fernández-Breis, M. Iniesta, M. Dumontier, M. E. Aranguren, S. Schulz, N. Aussenac-Gilles, and R. Stevens. Evaluation of the oquare framework for ontology quality. *Expert Systems with Applications*, 40(7):2696–2703, 2013.
- [5] A. Duque-Ramos, J. T. Fernández-Breis, R. Stevens, and N. Aussenac-Gilles. OQuARE: A SQuaRE-based approach for evaluating the quality of ontologies. *Journal of Research and Practice in Information Technology*, 43(2):159–176, 2011.
- [6] A. Duque-Ramos, M. Quesada-Martínez, M. Iniesta-Moreno, J. T. Fernández-Breis, and R. Stevens. Supporting the analysis of ontology evolution processes through the combination of static and dynamic scaling functions in oquare. *Journal of Biomedical Semantics*, 7(1):63, 2016.
- [7] J. T. Fernández-Breis, J. A. Maldonado, M. Marcos, M. d. C. Legaz-García, D. Moner, J. Torres-Sospedra, A. Esteban-Gil, B. Martínez-Salvador, and M. Robles. Leveraging electronic healthcare record standards and semantic web technologies for the identification of patient cohorts. *J Am Med Inform Assoc*, 20(e2):e288–96, Dec 2013.
- [8] J. T. Fernández-Breis, M. Quesada-Martínez, and A. Duque-Ramos. Can existing biomedical ontologies be more useful for ehr and cds? In *International Workshop on Knowledge Representation for Health Care*, pages 3–20. Springer, 2016.
- [9] J. Fox, N. Johns, and A. Rahmzadeh. Disseminating medical knowledge: the proforma approach. *Artif Intell Med*, 14(1-2):157–81, 1998.
- [10] C. Goble and R. Stevens. State of the nation in data integration for bioinformatics. *Journal of biomedical informatics*, 41(5):687–693, 2008.
- [11] M. d. C. Legaz-García, M. Menárguez-Tortosa, J. T. Fernández-Breis, C. G. Chute, and C. Tao. Transformation of standardized clinical models based on owl technologies: from cem to openehr archetypes. *J Am Med Inform Assoc*, 22(3):536–44, May 2015.
- [12] J. A. Maldonado, M. Marcos, J. T. Fernández-Breis, E. Parceró, D. Boscá, M. D. C. Legaz-García, B. Martínez-Salvador, and M. Robles. A platform for exploration into chaining of web services for clinical data transformation and reasoning. *AMIA Annu Symp Proc*, 2016:854–863, 2016.
- [13] C. Martínez-Costa. *Modelos de representación y transformación para la interoperabilidad semántica entre estándares de Historia Clínica Electrónica basados en arquitectura de modelo dual*. PhD thesis, Universidad de Murcia, 2011.
- [14] C. Martínez-Costa, M. Menárguez-Tortosa, and J. T. Fernández-Breis. An approach for the semantic interoperability of iso en 13606 and openehr archetypes. *J Biomed Inform*, 43(5):736–46, Oct 2010.
- [15] M. Menárguez-Tortosa and J. T. Fernández-Breis. Owl-based reasoning methods for validating archetypes. *Journal of biomedical informatics*, 46(2):304–317, 2013.
- [16] M. Quesada-Martínez. *Methodology for the enrichment of biomedical knowledge resources*. PhD thesis, Depto. de Informática y Sistemas. Univ. de Murcia, 2015.
- [17] M. Quesada-Martínez, A. Duque-Ramos, M. Iniesta-Moreno, and J. T. Fernández-Breis. Preliminary analysis of the obo foundry ontologies and their evolution using oquare. *Informatics for Health: Connected Citizen-Led Wellness and Population Health*, 235:426, 2017.
- [18] M. Quesada-Martínez and J. T. Fernández-Breis. Studying the reuse of content in biomedical ontologies: An axiom-based approach. In *Conference on Artificial Intelligence in Medicine in Europe*, pages 3–13. Springer, 2017.
- [19] M. Quesada-Martínez, J. T. Fernández-Breis, and D. Karlsson. Suggesting missing relations in biomedical ontologies based on lexical regularities. *Stud Health Technol Inform*, 228:384–8, 2016.
- [20] M. Quesada-Martínez, J. T. Fernández-Breis, and R. Stevens. Lexical characterization and analysis of the bioportal ontologies. In *Conference on Artificial Intelligence in Medicine in Europe*, pages 206–215. Springer Berlin Heidelberg, 2013.
- [21] M. Quesada-Martínez, J. T. Fernández-Breis, and R. Stevens. Lexical characterisation of bio-ontologies by the inspection of regularities in labels. *Current Bioinformatics*, 10(2):165–176, 2015.
- [22] M. Quesada-Martínez, M. Marcos, F. Abad-Navarro, B. Martínez-Salvador, and J. T. Fernández-Breis. Towards the semantic enrichment of computer interpretable guidelines: a method for the identification of relevant ontological terms. In *AMIA Annual Symposium Proceedings*, 2018.
- [23] M. Quesada-Martínez, E. Mikroyannidi, J. T. Fernández-Breis, and R. Stevens. Approaching the axiomatic enrichment of the gene ontology from a lexical perspective. *Artificial intelligence in medicine*, 65(1):35–48, 2015.
- [24] V. Stroetman, D. Kalra, P. Lewalle, A. Rector, J. Rodrigues, K. Stroetman, G. Surjan, B. Ustun, M. Virtanen, and P. Zanstra. Semantic Interoperability for Better health and Safer Healthcare [34 pages]. (January), 2009.
- [25] A. Third. Hidden semantics: what can we learn from the names in an ontology? In *Proceedings of the Seventh International Natural Language Generation Conference*, pages 67–75. Association for Computational Linguistics, 2012.
- [26] P. van Damme, M. Quesada-Martínez, R. Cornet, and J. T. Fernández-Breis. From lexical regularities to axiomatic patterns for the quality assurance of biomedical terminologies and ontologies. *J Biomed Inform*, Jun 2018.

# Resolución de Problemas Biomédicos mediante Técnicas de Extracción de Conocimiento

Oscar Reyes, Jose M. Luna, Jose M. Moyano, Eduardo Pérez y Sebastián Ventura

Dpto. Informática y Análisis Numérico, Universidad de Córdoba

Instituto Maimónides de Investigación Biomédica de Córdoba

Email: {ogreyes; jmluna; jmoyano; z72pepee; sventura}@uco.es

**Resumen**—En este trabajo se presenta el grupo “*Descubrimiento de Conocimiento y Sistemas Inteligentes en Biomedicina*” del Instituto Maimónides de Investigación Biomédica de Córdoba. Este grupo, de reciente creación, está integrado por varios investigadores interesados en las áreas de extracción de conocimiento y desarrollo de sistemas inteligentes, con especial interés en la resolución de problemas de análisis de datos aplicados al ámbito de la biomedicina. A lo largo del documento, se describen brevemente algunas de las líneas de trabajo del grupo, así como algunos de los resultados alcanzados recientemente.

## I. INTRODUCCIÓN

En los últimos años, las técnicas de inteligencia artificial se han revelado como una herramienta muy potente para la resolución de problemas complejos en el ámbito de la biomedicina [1]. De todas estas técnicas, merecen una mención especial el aprendizaje automático y la minería de datos, que han posibilitando la extracción automática de conocimiento útil a partir de bases de datos biomédicas de gran tamaño y complejidad [2, 3].

Este interés por una explotación de las distintas bases de datos existentes, que se generan como consecuencia tanto de la información masiva que generan las nuevas técnicas de diagnóstico [4] como de los cada vez más populares registros electrónicos de salud [5] está provocando un creciente interés por las disciplinas que integran la denominada ciencia de datos [6]. Los investigadores en biomedicina ya no solo saben estadística clásica, sino que empiezan a incorporar a sus estudios técnicas avanzadas de análisis de datos e incorporan a sus equipos especialistas en estas disciplinas que les ayuden a resolver los problemas que se plantean al intentar explotar estas nuevas fuentes de información. Un ejemplo de esta evolución se puede apreciar analizando los planes estratégicos de instituciones como el Instituto Maimónides de Investigación Biomédica de Córdoba<sup>1</sup> (IMIBIC), que contempla para el quinquenio 2016-2020 acciones para incorporar científicos de datos a sus equipos de trabajo, los cuáles proporcionarán este nuevo valor añadido al desarrollo de las investigaciones realizadas en la institución. Los expertos del IMIBIC reconocen que la ciencia de datos juega un papel fundamental hoy en día en el diagnóstico médico, especialmente con el desarrollo de la medicina de precisión, que está posibilitando la puesta a punto de estrategias inteligentes para la prevención, diagnóstico y

tratamiento adaptados al perfil clínico, genético y molecular de cada paciente y cada enfermedad concreta.

Otra de las muestras del interés que suscita la aplicación de este tipo de técnicas entre los investigadores de biomedicina es la incorporación a estas instituciones de equipos, tanto técnicos como investigadores, especializados en el análisis de datos. Este es el caso del grupo *Descubrimiento de Conocimiento y Sistemas Inteligentes en Biomedicina*, al que pertenecen los autores del presente trabajo. Este es un grupo de investigación cuyos integrantes proceden del área de extracción de conocimiento y que, en los últimos años, tras su incorporación al instituto, han ido aumentando su interés por la resolución de problemas relacionados con el análisis de datos biomédicos, debido al interés que estos plantean desde el punto de vista aplicado y la complejidad de los mismos, que plantean interesantes retos desde el punto de vista teórico. El objetivo de este trabajo es presentar brevemente las líneas de investigación que desarrolla el grupo actualmente, así como algunos de los resultados alcanzados en colaboración con otros equipos de investigación del IMIBIC.

El resto del trabajo se organiza de la siguiente manera. En la Sección II se presenta la composición del grupo, se explican brevemente sus principales líneas de investigación y se mencionan las colaboraciones con otros grupos de investigación. Algunos de los estudios realizados por el grupo se presentan en la Sección III. Finalmente, en la Sección IV se presentan las conclusiones del presente trabajo.

## II. COMPOSICIÓN DEL GRUPO, LÍNEAS DE INVESTIGACIÓN Y COLABORACIONES

El grupo *Descubrimiento de Conocimiento y Sistemas Inteligentes en Biomedicina* se incorporó al IMIBIC en el año 2014. Dicho grupo está formado por investigadores del grupo de investigación *Knowledge Discovery and Intelligent Systems* (KDIS) de la Universidad de Córdoba<sup>2</sup>, interesados en aplicar los algoritmos que llevan desarrollando desde el año 2009 a problemas biomédicos. El grupo actualmente está compuesto por 10 investigadores doctores y 5 estudiantes de doctorado. El investigador principal del grupo es el Dr. Sebastián Ventura Soto.

Los dos campos principales en los cuales se centran los estudios realizados por el grupo son: el descubrimiento de

<sup>1</sup><https://www.imibic.org>

<sup>2</sup><http://uco.es/kdis>



conocimiento y minería de datos, así como la aplicación de técnicas de inteligencia artificial para el desarrollo de sistemas inteligentes. La línea de trabajo que el grupo se propone desarrollar en los siguientes años se enfoca en el desarrollo de metodologías de análisis de datos para resolver problemas complejos de biomedicina de gran relevancia para la sociedad, como son la predicción de melanoma, el estudio de los factores de splicing alternativo, la predicción y descripción de patologías en hipertensión arterial, entre otros.

## II-A. Líneas de investigación

A continuación se presentan brevemente las líneas de investigación que desarrolla el grupo.

*II-A1. Desarrollo de modelos predictivos:* Las técnicas de aprendizaje supervisado permiten que el conocimiento aportado por los expertos pueda guiar el análisis de los datos, mostrándole a los algoritmos cuáles son las conclusiones (salidas) a la cuales deben llegar. Por ejemplo, un algoritmo de clasificación de imágenes para el diagnóstico del melanoma tratará de aprender las relaciones que vinculan a los datos contenidos en las imágenes con las etiquetas asignadas [7]. De esta manera, los algoritmos de aprendizaje supervisado permiten, dado unos datos de entrada, encontrar una función que produce una salida lo más aproximada posible al conocimiento de los expertos. Los modelos predictivos se pueden clasificar teniendo en cuenta el tipo de salida en modelos de clasificación (salida discreta) y modelos de regresión (salida continua). Por otra parte, los modelos de clasificación y regresión tradicionales producen una única salida a partir de un único vector de variables descriptoras. Sin embargo, en los últimos años la construcción de modelos a partir de representaciones de datos más flexibles (multi-instancia, multi-vista, multi-etiqueta, multi-salida) ha sido de gran interés en la comunidad científica.

Los estudios realizados por el grupo en este campo se basan en el desarrollo de modelos predictivos, tanto para problemas clásicos de predicción [8] como para problemas con representaciones más flexibles [9–12]. Alguno de estos estudios han sido aplicados directamente a problemas de Biomedicina; por ejemplo, en la predicción del riesgo de padecer diabetes y en el diagnóstico a partir de textos clínicos usando modelos de clasificación multi-etiqueta.

*II-A2. Minería de patrones:* Los patrones, como elemento clave en el análisis de datos, representan cualquier tipo de homogeneidad y regularidad en los datos, y por lo tanto estos sirven como descriptores de propiedades importantes presentes en los datos. Las técnicas de minería de patrones son comúnmente de carácter descriptivo y no supervisado, por lo que no se requiere incorporar conocimiento experto al comienzo de un estudio [13]. En ocasiones, dichas tareas descriptivas se enfocan en variables objetivo y, por tanto, tienen cierto carácter supervisado [14].

Los estudios realizados por el grupo en este campo se enfocan en la extracción de conocimiento a partir de datos originales y el descubrimiento de información útil asociada a variables específicas de interés. Se estudian diferentes tipos de

patrones, incluyendo patrones frecuentes e infrecuentes [15], y patrones definidos sobre diferentes tipos de datos como relacionales, secuenciales, y en dominios ambiguos [13, 14]. Por otra parte, el grupo desarrolla algoritmos para la minería de patrones respecto a una (o múltiples) variable objetivo, incluyendo algoritmos de descubrimiento de sub-grupos [16] y algoritmos para modelos excepcionales [17], entre otros.

*II-A3. Desarrollo de Modelos Big Data:* Hoy en día los sistemas de información producen colecciones masivas de datos que superan las capacidades de procesamiento y almacenamiento de los métodos de extracción de conocimiento tradicionales. Los problemas *Big Data* se caracterizan por grandes volúmenes de datos, que se generan comúnmente a gran velocidad, con gran variedad de formatos, donde es necesario garantizar la veracidad de los datos y por último extraer el valor (conocimiento) oculto en ellos. [18]

En los últimos años, los investigadores se han enfocado principalmente en la mejora de la escalabilidad de los algoritmos para enfrentar correctamente el desafío que conlleva el tratamiento de grandes volúmenes de datos. Este desafío es especialmente acentuado en el campo de la biomedicina, donde podemos encontrar enormes bases de datos genéticos y bases de datos de historias clínicas. Sin embargo, una integración efectiva y eficiente de todos los datos biomédicos disponibles a partir de diferentes fuentes con el objetivo de extraer conocimiento útil y no trivial no es sencilla ni directa en la mayoría de los casos [19]. En este sentido, el grupo de investigación ha desarrollado algunos modelos [15, 16, 20, 21], los cuales pueden ser aplicados a problemas *Big Data* en el campo de la Biomedicina.

*II-A4. Desarrollo de flujos de trabajo:* Los flujos de trabajo o *workflows* son mecanismos de alto nivel que permiten automatizar y describir procesos como una serie de actividades interconectadas que producen una salida deseada. En el caso del análisis de datos, los *workflows* ofrecen una serie de pasos para conducir el análisis teniendo en cuenta las características de los dominios de aplicación, ocultando los requerimientos computacionales y detalles técnicos de las técnicas de análisis, y facilitando el desarrollo de procesos complejos para la extracción de conocimiento a partir de datos heterogéneos [22].

La aplicación de los *workflows* en ciencia de datos enfrenta varios desafíos, que no solo se relacionan con la descomposición de los métodos de extracción de conocimiento en procesos y actividades, sino también con la adaptación y disposición de procedimientos algorítmicos de bajo nivel para el análisis intensivo de datos. Por otro lado, los *workflows* para problemas *Big Data* requieren el análisis de métodos paralelizables de minería de datos, su ejecución en clusters o sistemas basados en la nube, la optimización de los procesos para la ejecución eficiente de tareas complejas, etc. En este campo, el grupo está trabajando en la construcción de soluciones basadas en *workflows* [23–25], con el objetivo principal de mejorar la aplicación y reusabilidad de las metodologías propuestas para el análisis de datos en los estudios biomédicos que se realizan en el IMIBIC.

## II-B. Colaboraciones

El grupo de investigación colabora activamente con varios grupos del IMIBIC, entre los que podemos mencionar:

- Grupo GC-05 “*Enfermedades autoinmunes sistémicas-inflamatorias crónicas del aparato locomotor y tejido conectivo*” - Inv. principal Dra. Rosario López Pedrera. Se colabora en estudios para la determinación de los factores más relevantes en enfermedades autoinmunes y cardiovasculares, y además se analiza cómo estas enfermedades incrementan el riesgo de ictus y de mortalidad.
- GC-07 “*Nefrología. Daño celular en la inflamación crónica*” - Inv. principal Dr. Pedro Aljama García. Se está colaborando en la obtención de nuevos parámetros hemodinámicos ambulatorios y medicina de precisión.
- Grupo GC-08 “*Hormonas y Cáncer*” - Inv. principal Dr. Justo P. Castaño Fuentes. Se colabora en el estudio de los principios celulares y moleculares involucrados en los procesos naturales de la regulación neuroendocrino-metabólica y sus disfunciones en enfermedades tumorales y cáncer. Actualmente los estudios se centran principalmente en la detección de los factores de la maquinaria de *splicing* que más inciden en el desarrollo de diversas enfermedades, tales como el cáncer de próstata, tumores cerebrales y neuroendocrinos.
- Grupo GC-09 “*Nutrigenómica. Síndrome metabólico.*” - Inv. principal Dr. José López Miranda. Se ha colaborado en el desarrollo de modelos que detecten y expliquen los diferentes factores que influyen en el desarrollo de la diabetes mellitus tipo II.
- Grupo GC-26 “*Virología clínica y zoonosis*” - Inv. principal Dr. Antonio Rivero Román. Se realizan estudios para el diagnóstico y el diseño de estrategias de prevención de enfermedades virales (como la hepatitis) que tienen un alto riesgo en la salud de la población.
- Grupo GC-27 “*OncObesidad y metabolismo*” - Inv. principal Dr. Raúl M. Luque Huertas. Se colabora en el estudio de las bases celulares, moleculares y fisiopatológicas que influyen en el desarrollo y la progresión de enfermedades metabólicas, como la obesidad y la diabetes. Actualmente los estudios se centran principalmente en la detección de los factores de la maquinaria de *splicing* que más inciden en el desarrollo de esteatosis y diabetes mellitus tipo II.

## III. ESTUDIOS Y RESULTADOS

En esta sección se describen en más detalle algunos de los estudios ya realizados por el grupo y sus resultados principales, así como estudios que se están realizando y que no están concluidos.

### III-A. Metodología para la determinación de factores relevantes

Se ha desarrollado una metodología basada en técnicas de aprendizaje supervisado que permite la extracción de subconjuntos de factores relevantes para una correcta clasificación de las muestras en las clases definidas por los expertos. Esta

metodología consta de dos fases principales: (a) la determinación de la importancia de los factores, que permite determinar un ranking de importancia; y (b) la construcción de modelos de clasificación a partir de dicho ranking. El uso de esta metodología puede aportar varios beneficios al análisis de datos biomédicos, ya que no solo se pueden determinar subconjuntos de factores relevantes que influyen en la correcta clasificación de las muestras, sino que los métodos desarrollados también son capaces de detectar distribuciones conjuntas entre factores, e interacciones y dependencias complejas respecto a las clases.

La metodología ha sido utilizada en diferentes estudios realizados en colaboración con varios de los grupos mencionados anteriormente en la Sección II-B. A continuación se describen brevemente tres de los estudios realizados que muestran la aplicación y utilidad de la metodología propuesta.

**III-A1. Diagnóstico de tumores neuroendocrinos pulmonares:** En colaboración con el grupo GC-08 “*Hormonas y Cáncer*” del IMIBIC se realizó un estudio para el diagnóstico de tumores neuroendocrinos pulmonares. La heterogeneidad, sus diferentes comportamientos clínicos, y la posibilidad de aparición recurrente y de metástasis a largo plazo, enfatiza la importancia que tiene la identificación de nuevos marcadores de diagnósticos y terapéuticos que pueden mejorar el diagnóstico, pronóstico y/o el tratamiento de los pacientes que sufren esta enfermedad [26].

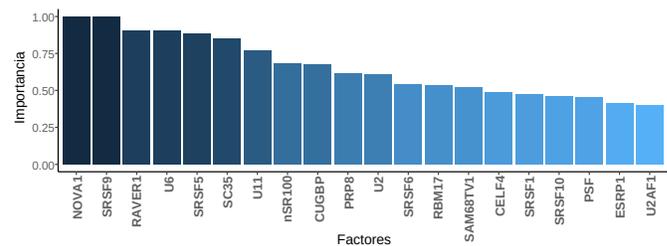


Figura 1. Ranking de factores para diferenciar entre muestras normales y tumorales.

Para este problema, los datos disponibles fueron de 26 muestras pareadas (muestras tumorales con su respectiva muestra de tejido normal adyacente), donde por cada muestra se tenía la expresión de 44 factores que regulan la maquinaria de *splicing*. Mediante la primera fase de la metodología propuesta se obtuvo un ranking de factores que permitió determinar cuáles son en promedio los factores más relevantes para diferenciar las clases de muestras. La Figura 1 muestra las importancias de los 20 primeros factores del ranking.

Posteriormente, en la segunda fase de la metodología se encontraron 100 modelos con AUC mayor o igual a 0,85, arrojando subconjuntos de factores relevantes que aparecen generalmente en todos los modelos predictivos. Tras realizar el análisis, los factores más relevantes encontrados fueron validados mediante pruebas de laboratorio.

**III-A2. Aclaramiento espontáneo en Hepatitis C:** En colaboración con el grupo GC-26 “*Virología clínica y zoonosis*” del IMIBIC se realizó un estudio para identificar factores o marcadores que ayuden a la predicción del aclaramiento espontáneo



En la actualidad, el grupo está trabajando en dos problemas diferentes y sobre los que no se tienen aún resultados plausibles o destacados, pues se encuentran en un estado muy prematuro.

*III-B1. Extracción de patrones de expresiones génicas para describir tipos de cáncer:* En colaboración con el grupo GC-08 “*Hormonas y Cáncer*” del IMIBIC se está realizando una serie de estudios para identificar y describir diferentes tipos de cáncer. El objetivo de este estudio es demostrar cómo técnicas de *Supervised Descriptive Pattern Mining* [14] pueden ser útiles en la descripción de tumores y cáncer. Las técnicas utilizadas no parten de un conocimiento previo, sino que analizarán todas y cada una de las variables existentes, pudiendo dar relaciones desconocidas e imposibles de obtener por técnicas clásicas comúnmente utilizadas en Biomedicina. Los primeros estudios realizados han demostrado que, sobre bases de datos ampliamente estudiadas en la literatura, las nuevas técnicas son capaces de obtener información ya conocida, lo cual demuestra la efectividad y validez de estos métodos. Así pues, se está trabajando en la aplicación de estas mismas técnicas sobre nuevos conjuntos de datos donde las técnicas clásicas están limitadas (requieren conocimiento previo de cuáles genes deben ser analizados).

*III-B2. Extracción de patrones para describir variables hemodinámicas:* En colaboración con el grupo GC-07 “*Nefrología. Daño celular en la inflamación crónica*” del IMIBIC se está realizando una serie de estudios para la obtención de nuevos parámetros hemodinámicos ambulatorios y personalizados de tratamientos antihipertensivos. La hipótesis fundamental de trabajo consiste en que la aplicación de los principios de la medicina de precisión en el campo de la enfermedad cardiovascular abrirán nuevas vías de intervención individualizadas que permitirá mejorar el pronóstico de los pacientes optimizando la prescripción racional del medicamento. Se usarán nuevas técnicas diagnósticas no invasivas así como técnicas de análisis de datos que permitirán identificar relaciones no conocidas hasta el momento entre variables hemodinámicas, tratamientos y pronóstico del paciente.

#### IV. CONCLUSIONES

En este trabajo se ha presentado el grupo “*Descubrimiento de Conocimiento y Sistemas Inteligentes en Biomedicina*” del IMIBIC, cuya línea de trabajo principal radica en el desarrollo de metodologías de análisis de datos para resolver problemas complejos de Biomedicina de gran relevancia para la sociedad. Se han descrito brevemente las líneas de investigación que actualmente desarrolla el grupo, y además se han presentado alguno de los estudios biomédicos en los cuales el grupo ha colaborado o que actualmente se están desarrollando, demostrando la importancia que tiene hoy en día la aplicación de técnicas modernas de ciencias de datos en los estudios biomédicos. Se espera que próximamente el grupo pueda extender su campo de acción a otros grupos de investigación biomédica del IMIBIC, así como fortalecer la colaboración con otros grupos externos.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto TIN2017-83445-P del Ministerio de Economía y Competitividad y Fondos FEDER.

#### REFERENCIAS

- [1] A. Kocheturov, P. M. Pardalos, and A. Karakitsiou, “Massive datasets and machine learning for computational biomedicine: trends and challenges,” *Annals of Operations Research*, pp. 1–30, 2018.
- [2] C. Cao, F. Liu, H. Tan, D. Song, W. Shu, W. Li, Y. Zhou, X. Bo, and Z. Xie, “Deep learning and its applications in biomedicine,” *Genomics, proteomics & bioinformatics*, 2018.
- [3] N. Tempini and S. Leonelli, “Genomics and big data in biomedicine,” in *Routledge Handbook of Genomics, Health and Society*. Routledge, 2018, pp. 44–51.
- [4] S. M. et al., “Intelligent and effective informatic deconvolution of “big data” and its future impact on the quantitative nature of neurodegenerative disease therapy,” *Alzheimer’s & Dementia*, 2018.
- [5] Y. Essa, G. Attiya, A. El-Sayed, and A. ElMahalawy, “Data processing platforms for electronic health records,” *Health and Technology*, pp. 1–10, 2018.
- [6] L. Garmire, S. Gliske, Q. Nguyen, J. Chen, S. Nemati, H. Van, D. John, J. Moore, C. Shreffler, and M. Dunn, “The training of next generation data scientists in biomedicine,” in *Pacific Symposium on Biocomputing*. World Scientific, 2017, pp. 640–645.
- [7] I. Giotis, N. Molders, S. Land, M. Biehl, M. F. Jonkman, and N. Petkov, “MED-NODE: A computer-assisted melanoma diagnosis system using non-dermoscopic images,” *Expert Systems with Applications*, vol. 42, no. 19, pp. 6578 – 6585, 2015.
- [8] B. Strack, J. P. DeShazo, C. Gennings, J. L. Olmo, S. Ventura, K. J. Cios, and J. N. Clore, “Impact of hba1c measurement on hospital readmission rates: analysis of 70,000 clinical database patient records,” *BioMed research international*, vol. 2014, 2014.
- [9] J. M. Luna, A. Cano, V. Sakalauskas, and S. Ventura, “Discovering useful patterns from multiple instance data,” *Information Science*, vol. 357, pp. 23–38, 2016.
- [10] E. Gibaja, J. M. Moyano, and S. Ventura, “An ensemble-based approach for multi-view multi-label classification,” *Progress in Artificial Intelligence*, vol. 5, no. 4, pp. 251–259, 2016.
- [11] O. Reyes, C. Morell, and S. Ventura, “Effective lazy learning algorithm based on a data gravitation model for multi-label learning,” *Information Sciences*, vol. 340, pp. 159–174, 2016.
- [12] O. Reyes, A. Cano, H. Fardoun, and S. Ventura, “A locally weighted learning method based on a data gravitation model for multi-target regression,” *International Journal of Computational Intelligence Systems*, vol. 11, no. 1, pp. 282–295, 2018.



- [13] S. Ventura and J. M. Luna, *Pattern mining with evolutionary algorithms*. Springer, 2016.
- [14] —, *Supervised Descriptive Pattern Mining*. Springer, 2018.
- [15] J. M. Luna, F. Padillo, M. Pechenizkiy, and S. Ventura, “Apriori versions based on mapreduce for mining frequent patterns on big data,” *IEEE Transactions on Cybernetics*, vol. 99, pp. 1–15, 2017.
- [16] F. Padillo, J. M. Luna, and S. Ventura, “Exhaustive search algorithms to mine subgroups on big data using Apache Spark,” *Progress in Artificial Intelligence*, vol. 6, no. 2, pp. 145–158, 2017.
- [17] J. M. Luna, M. Pechenizkiy, and S. Ventura, “Mining exceptional relationships with grammar-guided genetic programming,” *Knowledge and Information Systems*, vol. 47, no. 3, pp. 571–594, 2016.
- [18] S. Ventura, J. M. Luna, and A. Cano, *Big Data on Real-World Applications*. InTech, 2016.
- [19] R. Salado-Cid, A. Ramírez, and J. R. Romero, “On the need of opening the big data landscape to everyone: challenges and new trends.” Berlin, Heidelberg: Springer Berlin Heidelberg, 2018, pp. 675–687.
- [20] F. Padillo, J. M. Luna, and S. Ventura, “Subgroup discovery on big data: exhaustive methodologies using map-reduce,” in *Proceedings of the 2016 IEEE Trust-com/BigDataSE/ISPA*, 2016, pp. 1684–1691.
- [21] —, “An evolutionary algorithm for mining rare association rules: A big data approach,” in *2017 IEEE Congress on Evolutionary Computation, CEC 2017, Donostia, San Sebastián, Spain, June 5-8, 2017*, 2017, pp. 2007–2014.
- [22] R. Salado-Cid and J. R. Romero, “Enabling the definition and reuse of multi-domain workflow-based data analysis,” in *16th International Conference on Intelligent Systems Design and Applications (ISDA’16)*, 2016.
- [23] R. Salado-Cid, J. R. Romero, and S. Ventura, “Metaherramienta para la generación de aplicaciones científicas basadas en workflows,” in *X Jornadas de Ciencia e Ingeniería de Servicios (JCIS’14)*, 2014, pp. 96–105.
- [24] R. Salado-Cid, G. Luque, and J. R. Romero, “Sistema de gestión de flujos de trabajo para la definición visual de aplicaciones basadas en algoritmos evolutivos,” in *XVI Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA’15)*, 2015, pp. 261–270.
- [25] R. Salado-Cid and J. R. Romero, “Lenguaje específico para el modelado de flujos de trabajo aplicados a ciencia de datos,” in *XXI Jornadas en Ingeniería del Software y Bases de Datos (JISBD’16)*, 2016, pp. 227–240.
- [26] A. D. Herrera-Martínez, M. D. Gahete, R. Sánchez-Sánchez, R. O. Salas, R. Serrano-Blanch, A. Salvatierra, L. J. Hofland, R. M. Luque, M. A. Gálvez-Moreno, and J. P. Castaño, “The components of somatostatin and ghrelin systems are altered in neuroendocrine lung carcinoids and associated to clinical-histological features,” *Lung Cancer*, vol. 109, pp. 128–136, 2017.
- [27] M. Frias, A. Rivero-Juárez, D. Rodríguez-Cano, A. Camacho, P. López-López, M. Risalde, B. Manzanares-Martín, T. Brieva, I. Machuca, and A. Rivero, “HLA-B, HLA-C and KIR improve the predictive value of IFNL3 for Hepatitis C spontaneous clearance,” *Scientific Reports*, vol. 8, no. 1, p. 659, 2018.

# Una aproximación a la interpretación del electrocardiograma desde la perspectiva de la Inteligencia Artificial

Paulo Félix

*Centro Singular de Investigación en Tecnoloxías da Información (CiTIUS)*  
*Universidade de Santiago de Compostela*  
15782 Santiago de Compostela, SPAIN  
paulo.felix@usc.es

**Resumen**—En este trabajo se revisa la trayectoria científica reciente del Centro Singular de Investigación en Tecnoloxías da Información de la Universidade de Santiago de Compostela en la interpretación electrocardiográfica desde la perspectiva de los métodos, técnicas y herramientas asimilables a la Inteligencia Artificial.

**Index Terms**—Series temporales estocásticas, Electrocardiograma, Agrupamiento, Clasificación, Regresión, Abducción

## I. INTRODUCCIÓN

El electrocardiograma (ECG) es una prueba diagnóstica de bajo coste que consiste en el registro de la actividad eléctrica del corazón a partir de la medición de la diferencia de potencial entre un conjunto de electrodos colocados en la superficie de la piel del paciente. La interpretación del ECG plantea numerosos retos absolutamente fascinantes desde múltiples puntos de vista. Desde un punto de vista *asistencial*, se pretende la generalización de su uso en la prevención, diagnóstico y seguimiento de la enfermedad cardiovascular, primera causa de muerte en el mundo [1]. Desde un punto de vista *científico*, en tanto que se ha convertido en una fuente todavía sin agotar de información sobre multitud de procesos fisiopatológicos que se manifiestan de alguna manera en el ECG, y así, disciplinas como la neumología, la obstetricia, la neurología o incluso la psiquiatría, buscan evidencias en el ECG que permitan un abordaje sencillo y precoz en múltiples y variados trastornos. Desde un punto de vista *tecnológico*, en busca de una instrumentación más pequeña, más fiable, con mayor capacidad de interpretación, más eficiente y más autónoma, que pueda realizar un registro de la manera más inadvertida posible, como parte de los dispositivos que por su comodidad pueden considerarse vestibles. Desde un punto de vista *cognitivo*, en tanto que la interpretación del ECG que realiza un experto cardiólogo ha de poner en juego un conjunto de procesos mentales como la percepción, la memoria, el aprendizaje o la adaptación que son objeto de constante

revisión con la experiencia, en un problema que podríamos calificar como de parcialmente observable, y para el que no existen criterios de consenso, tal y como pone de manifiesto la diferente interpretación que realizan distintos expertos sobre el mismo registro [2].

Son estos retos cognitivos los que aquí interesan, desde la perspectiva de la Inteligencia Artificial, con el objetivo de dotar a la tecnología de una mayor capacidad de interpretación mediante nuevos métodos que permitan hacer computable el razonamiento, y simultáneamente, proporcionen nuevas herramientas para modelar el comportamiento de un sistema como sistema físico. Conviene revisar en este punto algunas de las dificultades que plantea el problema: 1) la variabilidad de los procesos fisiológicos y fisiopatológicos que subyacen en el trazo electrocardiográfico, variabilidad que se observa entre múltiples pacientes e incluso en el mismo paciente a lo largo del tiempo (Fig. 1); 2) la naturaleza estocástica de dichos procesos; 3) la ocurrencia simultánea de múltiples procesos fisiológicos que interaccionan entre sí de múltiples maneras; 4) la presencia de ruido y artefactos en la señal obtenida, ocultando la percepción de los procesos de interés; o 5) la ausencia de un modelo preciso del miocardio; y 6) el conocimiento tácito, subjetivo y difícilmente formalizable que forma parte de la experiencia del cardiólogo.

A continuación se presentan y discuten algunas de las propuestas que un mismo equipo científico ha realizado en los últimos años en este problema. Cabe decir que el ECG no ha sido el objeto de estudio, sino el banco de pruebas con el que experimentar nuevos modelos y técnicas de representación y razonamiento para los que la aspiración ha sido plantear soluciones generales a problemas generales. En esta trayectoria consideramos fundamental el papel de la iniciativa Physionet<sup>1</sup>, porque más allá de compilar múltiples colecciones de datos fisiológicos de referencia en los procesos de validación científica, constituye un agente dinamizador que ha asumido el papel de estimular y alinear el interés de la comunidad científica con los desafíos que afronta la medicina actual [3]. También queremos destacar nuestra colaboración

This work was partly funded by the Spanish MINECO under projects TIN2014-55183-R and TIN2009-14372-C03-03, from the Consellería de Cultura, Educación e Ordenación Universitaria da Xunta de Galicia and the European Regional Development Fund (ERDF) under Grant No. 2016-2019-ED431G/08

<sup>1</sup>[www.physionet.org](http://www.physionet.org)



con el Servicio de Cardiología del Complejo Hospitalario Universidade de Santiago de Compostela.

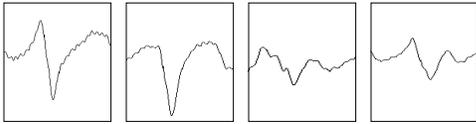


Figura 1. Evolución de la morfología de la clase de normalidad de un paciente a lo largo del tiempo.

## II. EL AGRUPAMIENTO MORFOLÓGICO DE LATIDOS

Los recientes desarrollos tecnológicos en sensores y dispositivos móviles han facilitado la aparición de nuevos escenarios para una monitorización del ECG de larga duración, lo que permite la detección temprana de determinados eventos relevantes, que con frecuencia ocurren de manera esporádica. A medida que el período de registro aumenta (considerando habitual que sea de 24 horas) la tarea de interpretación exige más tiempo, y parece ineludible demandar nuevas herramientas de apoyo a la decisión. Su objetivo es realizar un resumen efectivo del registro electrocardiográfico, llamando la atención sobre las anomalías detectadas.

Entre todos los posibles hallazgos que requieren atención sobre el ECG, las arritmias cardíacas son las más relevantes. Se distinguen dos tipos de arritmias: 1) aquéllas en cuyo origen hay un trastorno del automatismo, esto es, un conjunto de alteraciones en el foco de activación del latido, ya sea en el lugar del miocardio donde se origina o en la frecuencia de activación; o 2) un trastorno de la conducción, esto es, una propagación anormal del frente de onda del latido a lo largo del tejido cardíaco. Ambos son reconocibles en el ECG, bien porque afectan a la morfología del latido, o a su ritmo de aparición.

Dos son las estrategias que se encuentran en la bibliografía científica para abordar la identificación de arritmias: la clasificación y el agrupamiento. La clasificación, fundamentalmente clasificación de latidos, busca asignar a cada latido una etiqueta que identifica su naturaleza fisiológica. De manera mayoritaria, esto se logra mediante alguna técnica de aprendizaje automático entrenada sobre un conjunto de entrenamiento. La principal dificultad de esta aproximación estriba en su dependencia de la diversidad morfológica presente en el conjunto de entrenamiento, lo que conduce a menudo a resultados decepcionantes sobre nuevos registros de ECG [4]. Además, las clases sólo proporcionan información sobre el origen del latido, dejando al margen la información sobre el camino de conducción, lo que impide distinguir entre las múltiples familias morfológicas que comparten el mismo origen y, por tanto, pertenecen a la misma clase, como ocurre en el caso de las arritmias multifocales.

El agrupamiento, en cambio, se limita a dividir el registro de ECG en un conjunto de grupos de latidos, de modo que cada uno de ellos preserva algunas propiedades de semejanza. Aquí tradicionalmente se han venido publicando propuestas en las que se fija a priori un número máximo de grupos,

y el agrupamiento se realiza en diferido sobre la totalidad del registro. Esto tiene la ventaja de lograr una razonable robustez frente al ruido, pero por contra, suele distribuir los ejemplos de una misma morfología entre distintos grupos, y penaliza la identificación de morfologías raras, que acaban ocultas en grupos ajenos. Por otra parte, esta aproximación obvia el carácter dinámico del ECG y, en particular, ignora la evolución temporal de las distintas morfologías. Además, la detección de eventos de carácter crítico se pospone demasiado como para proporcionar una respuesta oportuna.

En [5] proponemos un método adaptativo para el agrupamiento de latidos, con el potencial de servir de paso previo a una técnica de clasificación, o de resumen sobre aquellas morfologías presentes en un cierto período de tiempo, su evolución temporal y su variabilidad.

Adoptamos una estrategia inspirada en la percepción visual, que reduce el contorno de cada imagen a un conjunto de puntos de máxima curvatura respecto al contexto, puntos que concentran la información más relevante y reconocible de la imagen, y así extraemos del trazo electrocardiográfico un conjunto de puntos dominantes a partir de los cuales se realiza una caracterización de las ondas constituyentes del latido cardíaco. La similitud entre latidos se calcula mediante la técnica de *Dynamic Time Warping*, lo que permite por un lado realizar un alineamiento no lineal entre el latido actual y el representante de cada uno de los grupos, y por otro, reducir la variabilidad estocástica de la señal con el fin de obtener una asignación correcta del latido al grupo más semejante. El método hace uso de un conjunto reducido de parámetros, pero todos ellos toman valores cuya justificación es exclusivamente fisiológica, ajenos a la necesidad de responder adecuadamente a algún conjunto de entrenamiento.

El método propuesto emula el comportamiento del experto cardiólogo en tanto que explota la información presente en el contexto temporal de cada latido con el fin de realizar la asignación de cada nuevo latido al grupo más apropiado. Así, los distintos grupos se adaptan continuamente a la evolución temporal de las morfologías de los nuevos latidos, pudiendo crearse dinámicamente nuevos grupos, modificarse grupos previos, o fusionarse varios grupos en uno solo, de modo que el número de grupos resultante se adapta a la variabilidad morfológica del registro analizado. El método es eficiente y puede ejecutarse en tiempo real en una computadora de propósito general.

Se ha realizado una validación de este método con la *MIT-BIH Arrhythmia database*, base de datos de referencia en la bibliografía científica para problemas de clasificación y agrupamiento en electrocardiografía. El método proporciona una medida de pureza del 98.56%, ligeramente superior al mejor resultado previo de la bibliografía, de 98.49%, que realiza un agrupamiento en diferido, con un número de grupos fijado a priori, y excesivo en el caso de muchos registros de la base de datos [7]. Como se ha dicho, los parámetros del método propuesto no surgen de un proceso de entrenamiento, ni se han ajustado a la base de datos de validación. El método muestra una escasa sensibilidad a pequeñas variaciones de

dichos parámetros, y aunque se pueden obtener mejoras en los resultados mediante un ajuste fino de los parámetros a cada base de datos, no es ese el objetivo del trabajo, sino mostrar la validez de la propuesta en un problema de monitorización continua en el que las características de los grupos evolucionan con el tiempo.

### III. ANÁLISIS DE PROCESOS ESTOCÁSTICOS

El análisis de la Variabilidad de la Frecuencia Cardíaca (VFC) constituye un dominio de estudio por sí mismo, concitando en los últimos años un gran interés en la comunidad científica. El término se refiere en general al estudio de la serie de las distancias temporales entre latidos consecutivos, medida como diferencia entre las correspondientes ondas R. El interés en la VFC surge de su capacidad para mostrar información sobre los mecanismos reguladores del sistema nervioso autónomo: sistema simpático, parasimpático y sistema renina-angiotensina, y de ahí su utilidad en el estudio de múltiples patologías, cardíacas y no cardíacas [8].

En el análisis de la VFC se observa en primer lugar un espectro de banda ancha, característico de los procesos con memoria a largo plazo, así como una estructura autosemejante, característica de los procesos fractales. De hecho, algunas de las características fractales de la VFC se han mostrado como eficaces predictores de fallo cardíaco e infarto de miocardio [9]. Así todo, resulta evidente que el corazón responde de una manera determinista en situaciones caracterizadas por una particular demanda: aumentando la frecuencia del latido ante la activación del sistema simpático, y reduciéndola ante la activación del parasimpático. Por otra parte, existen acoplamientos bien conocidos entre el miocardio y otros sistemas del organismo, y así por ejemplo, resulta evidente la traza de la respiración (y todas sus anomalías) en la VFC.

Parece por tanto razonable conjeturar que la VFC es el resultado de un conjunto de procesos deterministas y estocásticos que concurren en el control del miocardio. Desde esta premisa, conjeturamos un modelo de superposición en el que la serie RR es la suma  $RR[n] = x[n] + B[n]$ ,  $n = 1, \dots, N$  de una componente determinista  $x[n]$  limitada en banda y una componente fractal estocástica  $B[n]$  que responde a las características del movimiento fraccional browniano [9]. Dado que el movimiento fraccional browniano se caracteriza por ser no estacionario y, por tanto, variable en el tiempo, y autosemejante, esto es, con las mismas propiedades estadísticas en distintas escalas, se propone analizar la distribución de energía mediante la transformada *wavelet* de la serie original. Nuestra propuesta parte de una observación relevante: la energía de los procesos autosemejantes cambia con la escala siguiendo una relación en forma de ley de potencia, y las desviaciones respecto a este comportamiento permiten la estimación del proceso determinista superpuesto  $x[n]$ .

Se propone por tanto un método para la estimación simultánea de las componentes deterministas y estocásticas de naturaleza fractal en series temporales no estacionarias [9], y se aplica a un problema bien conocido, la identificación del Síndrome de Apnea-Hipopnea Obstruktiva del Sueño (SAOS)

a partir únicamente de la serie RR. El SAOS es un trastorno del sueño caracterizado por el cese total (apnea) o parcial (hipopnea) del flujo respiratorio durante el sueño del paciente. En episodios prolongados de apnea, el ritmo cardíaco muestra una secuencia característica de bradicardia-taquicardia, bradicardia en el comienzo del cese del flujo y taquicardia durante la recuperación del flujo.

El método propuesto se ha aplicado a la *Apnea-ECG database* [10], base de datos formada por un conjunto de registros de ECG de pacientes con SAOS, y anotados con los episodios de ocurrencia de apnea, proporcionando una exactitud en la identificación de episodios de apnea del 87.62%, por debajo del resultado del mejor clasificador publicado, del 92.62%. En aquellos registros de la base de datos en los que el método resulta eficaz la eliminación de la componente fractal facilita el reconocimiento de la secuencia bradicardia-taquicardia (Fig. 2).

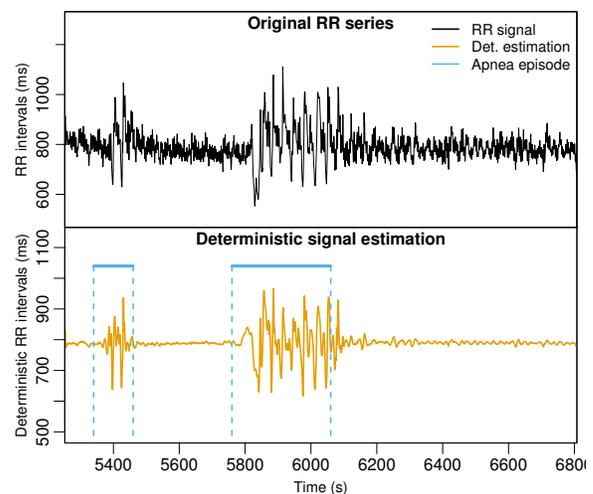


Figura 2. Estimación de la componente determinista sobre una serie RR y anotación de las apneas presentes en el registro.

En estos casos se pondría de manifiesto que durante el episodio de apnea las componentes deterministas del sistema nervioso toman el control para responder a la hipoxia que se produce durante la apnea; y por contra, en condiciones de reposo, la componente estocástica prevalecería. Sin embargo, en algunos registros de la base de datos nuestro método proporciona un resultado incorrecto, lo que sugiere que el problema reside en el carácter aditivo del modelo de partida, que ignora las posibles interacciones entre las componentes estocásticas y deterministas. En dichos registros parece que la aparición de ciertas componentes armónicas (como sucede en el acoplamiento con la respiración) inhibiría el proceso fractal estocástico, invalidando nuestra hipótesis inicial.

Probado este método en algunas series de datos de carácter económico, como la serie de precios de gasolina, se demuestra que permite una separación de componentes que hace aflorar comportamientos deterministas útiles en el análisis, como el llamado “efecto lunes” que compensa con bajadas de precios las subidas de los fines de semana [9].



Esta línea de trabajo ha continuado con el planteamiento del análisis de series temporales mediante ecuaciones diferenciales estocásticas, debido a su carácter interpretable. Dichas ecuaciones conjugan una ecuación determinista de movimiento con la existencia de fluctuaciones que interfieren en la dinámica del sistema en forma de ruido. Nuestra propuesta realiza una estimación de los coeficientes de la ecuación a partir de una serie temporal densa, haciendo uso de un procedimiento de regresión no paramétrica basada en procesos gaussianos dispersos y en un marco de razonamiento bayesiano [11]. Esta propuesta se ha aplicado con buenos resultados a series de datos económicas y a problemas de paleoclimatología, pero todavía no con acierto a series temporales fisiológicas o, en particular, de cardiología.

#### IV. INTERPRETACIÓN ABDUCTIVA DEL ECG

La comunidad científica ha dedicado una gran atención y esfuerzo al desarrollo de paradigmas, estrategias, metodologías y técnicas destinadas a la clasificación de series temporales. Sin embargo, y a pesar del amplio catálogo de propuestas para el diseño de clasificadores, ya sea a partir de alguna representación del conocimiento del dominio, o mediante inducción a partir de un conjunto de observaciones, el clasificador resultante se comporta siempre como un sistema deductivo. La línea de investigación que aquí se expone parte de la hipótesis de que algunas de las más importantes debilidades de los actuales clasificadores proceden de su naturaleza deductiva, y que una aproximación abductiva puede superar algunas de esas debilidades.

Se propone un nuevo paradigma abductivo de interpretación de series temporales [12], y se escoge como ámbito de aplicación el ECG, en tanto que sobre él se proyecta el comportamiento eléctrico de aquellos procesos fisiológicos que concurren en el miocardio y, en su evolución a lo largo del tiempo, el cardiólogo encuentra evidencia para la identificación y caracterización de los fenómenos cardiacos.

La propia finalidad de la interpretación pone de manifiesto la primera limitación de la deducción como inferencia. Recordemos que una deducción contiene en sus conclusiones información que ya está implícitamente contenida en las premisas, y de ese modo podríamos decir que preserva la verdad. En este sentido, un clasificador simplemente asigna una etiqueta o un conjunto de etiquetas a las observaciones disponibles. Esta etiqueta puede nombrar un proceso o un mecanismo que subyace a lo observado, pero no es más que un término que resume el conjunto de premisas que satisfacen las observaciones. Por contra, la abducción, o inferencia de la mejor explicación, realiza el camino que va de las observaciones disponibles a las hipótesis que mejor las explican. Las conclusiones de la abducción contienen nueva información no contenida en las premisas, información con capacidad de predecir nueva evidencia, aunque de manera falible. La abducción, por tanto, amplía la verdad, llevándonos desde el lenguaje de las observaciones al lenguaje de los procesos y mecanismos subyacentes [13], y respondiendo así al reto de interpretación del ECG antes expuesto.

Ciertamente, el resultado proporcionado por un clasificador puede considerarse una conjetura, pero siempre desde un agente externo a él, ya que un clasificador, como sistema lógico, es monótono, y no puede refutar sus propias conclusiones. Las agrupaciones de clasificadores tratan de superar los errores de clasificadores individuales mediante la combinación de resultados. Así todo, su planteamiento sigue siendo de abajo a arriba, de los datos a las clases, y a partir de cierto nivel de distorsión en los datos el fallo es inevitable. Si la clasificación se realiza en un conjunto de niveles de abstracción, la monotonicidad del razonamiento propaga los errores a medida que aumentamos el nivel de abstracción, y con ello aumenta su impacto en el resultado. En cambio, desde la lógica de la abducción, cada nivel de abstracción representa un lenguaje de observación diferente, de modo que cada nueva observación se conjetura como la mejor explicación de las observaciones que se disponen en los niveles inferiores, y en el contexto de la información de los niveles superiores. La no monotonicidad de la abducción permite retractar cualquier observación en cualquiera de los niveles de abstracción a medida que se dispone de nueva información, en un proceso que integra un flujo de razonamiento de abajo a arriba y otro de arriba a abajo. Como consecuencia, la abducción permite conjeturar la ocurrencia de un proceso fisiológico a partir de un fragmento de ECG corrompido por ruido.

Por otra parte, un clasificador se construye sobre la hipótesis de que cada una de las clases resultantes constituyen categorías mutuamente excluyentes. En el lenguaje de procesos, se excluye la superposición de dos o más procesos, que tendría que representarse mediante un nuevo proceso, una nueva categoría diferente a las anteriores, y que conduce a una casuística artificiosa que añade una complejidad adicional a la interpretación de resultados. Por contra, la abducción puede alcanzar una conclusión a partir de la disponibilidad parcial de evidencia, y refinar el resultado conforme se dispone de nueva información. Esto permite inferir un conjunto de procesos como concurrentes en el tiempo, en tanto que explican la evidencia disponible en un fragmento de ECG y no son incompatibles entre ellos.

Siguiendo con el argumento anterior, en un clasificador la verdad de una conclusión se sigue de la verdad de todas sus premisas, y la ausencia de datos requiere de alguna estrategia de imputación que resulta ser una conjetura: una suerte de abducción para proseguir la deducción. En cambio, una interpretación abductiva se plantea como un ciclo de hipótesis y test, en el que la ausencia de información se integra de forma natural, en tanto que una hipótesis puede ser evocada por la más simple pieza de evidencia que resulta por ella explicada, de modo que los datos pueden ser incorporados de manera incremental en el razonamiento. Esta característica resulta completamente oportuna para el tipo de análisis variable en el tiempo que requiere la interpretación del ECG, donde datos futuros pueden exigir cambios en conclusiones previamente alcanzadas, y donde se puede exigir un resultado de la interpretación en cualquier momento del proceso de razonamiento, como la mejor explicación con la información

disponible.

El paradigma propuesto se apoya en la definición de un conjunto de patrones de abstracción. Un patrón de abstracción  $P = \langle h, M_P, C_P, \Theta_P \rangle$  representa un conjunto de restricciones  $C_P$  que debe satisfacer la evidencia, representada por un conjunto de hallazgos  $M_P$ , para poder conjeturar la observación de un determinado proceso  $h$ , junto con un procedimiento de observación  $\Theta_P()$  que proporciona un conjunto de medidas para las características del proceso observado. Un patrón de abstracción permite modelar un proceso de abstracción de manera abductiva, basado en la relación conjetural  $m \leftarrow h$  [14], que podemos leer como ‘la observación de un hallazgo  $m \in M_P$  nos permite conjeturar la observación del proceso  $h$  como una posible hipótesis explicativa’.

La definición de patrón de abstracción fija a priori el conjunto de hallazgos a partir de los que se puede conjeturar la observación de  $h$ . En general, sin embargo, un proceso no tiene una duración determinada a priori ni, por tanto, un número prefijado de hallazgos. Pensemos por ejemplo en el número indeterminado de latidos que constituye un episodio de ritmo normal en un individuo. Para soslayar esta limitación, se define una gramática de abstracción, basada en la teoría de lenguajes formales, como una gramática con atributos que permite generar dinámicamente un conjunto de patrones de abstracción, de manera similar a como las gramáticas formales generan las cadenas de un lenguaje. Disponemos así de un proceso constructivo que permite añadir de manera incremental nuevas restricciones a medida que se dispone de nuevos hallazgos, proporcionando una forma sistemática de ensamblar conocimiento mediante mecanismos bien conocidos de generación de lenguaje.

Un conjunto de gramáticas de abstracción permiten definir un modelo de abstracción, y junto con un conjunto de observaciones iniciales, que en nuestro caso se corresponderían con un fragmento de ECG, definen un problema de interpretación. Se define una interpretación como un conjunto de hipótesis que explican las observaciones iniciales. Y se define la solución del problema de interpretación como el conjunto de todas las interpretaciones mínimas que recubren las observaciones iniciales. Se ha de cumplir que una interpretación no puede incluir hipótesis mutuamente excluyentes.

Como era de esperar, se demuestra que la búsqueda de la solución de un problema de interpretación es un problema NP-completo. El objetivo se traslada a la búsqueda de una solución aproximada, para lo que se introduce un conjunto de principios que operan como heurísticas que permiten discriminar entre distintas interpretaciones: 1) un *principio de cobertura*, que muestra su preferencia por aquellas interpretaciones que explican más observaciones iniciales; 2) un *principio de simplicidad*, que muestra su preferencia por interpretaciones con un menor número de hipótesis; 3) un *principio de abstracción*, que muestra su preferencia por interpretaciones con un mayor nivel de abstracción; y 4) un *principio de predictibilidad*, que muestra su preferencia por interpretaciones que predicen adecuadamente la evidencia futura.

Se propone y diseña el algoritmo CONSTRUE() para la

búsqueda de soluciones en problemas de interpretación, que utiliza las heurísticas antes comentadas. Este algoritmo muestra las siguientes ventajas respecto a aproximaciones previas basadas en clasificadores deductivos: 1) evita la necesidad de construir una interpretación sobre una casuística exhaustiva de patrones (Fig. 3); 2) es capaz de proporcionar el resultado ‘no sé’, lo que resulta conveniente en ciertos fragmentos aquejados de ruido; 3) es capaz de sugerir o predecir la aparición de evidencia de la que no hay constancia clara; 4) la solución del problema de interpretación resulta explicable.

El algoritmo CONSTRUE() se ha aplicado en distintos problemas relacionados con la interpretación del ECG. Destacamos aquí dos aplicaciones que han sido objeto de publicación.

Por un lado, se ha realizado una clasificación de latidos según su origen, y se ha validado con la *MIT-BIH Arrhythmia database*. A partir de la abstracción realizada por CONSTRUE() sobre cada uno de los registros, se ha añadido una etapa final formada por un sencillo clasificador basado en reglas, para proporcionar las etiquetas con las que está anotada la base de datos. El resultado es el mejor de la bibliografía respecto a otros clasificadores automáticos, y está entre los mejores entre aquéllos que son asistidos por un experto para el etiquetado [15]. Resulta digno de mención que el conocimiento que utiliza CONSTRUE() no está ajustado a la base de datos de validación, es el mismo que se puede encontrar en un manual de electrocardiografía.

Por otro lado, se ha utilizado CONSTRUE() para resolver el reto planteado en 2017 de manera conjunta por la iniciativa *Physionet y Computing in Cardiology* para la identificación de fibrilación auricular en registros de corta duración en una derivación. En este caso la disparidad de criterios y la falta de consenso en la anotación de la base de datos de validación obligó a complementar los resultados proporcionados por CONSTRUE() con técnicas de aprendizaje automático, consiguiendo así el mejor resultado de todos los presentados a concurso [16].

## V. DISCUSIÓN

Se ha presentado un conjunto de trabajos de investigación que tienen como preocupación común el proporcionar soluciones para el análisis e interpretación de series temporales, mostrando su posible efectividad sobre la señal de ECG. En líneas generales, distinguimos dos estrategias diferenciadas en nuestra trayectoria y que tendrán continuidad en nuestro trabajo futuro: 1) Una estrategia de modelado de la serie temporal entendida como resultado de un conjunto poco conocido de procesos, deterministas y estocásticos, que probablemente interactúan entre sí de múltiples maneras todavía por conocer. Creemos que mediante la construcción de modelos es como podemos alcanzar un conocimiento profundo sobre cómo funcionan los sistemas que observamos mediante la evolución en el tiempo de algunas de sus características medibles. La construcción de modelos es un proceso laborioso e iterativo, en el que la inteligencia artificial, o el aprendizaje automático en particular, pueden proporcionar herramientas valiosas de estimación a partir de los datos disponibles. 2) Una

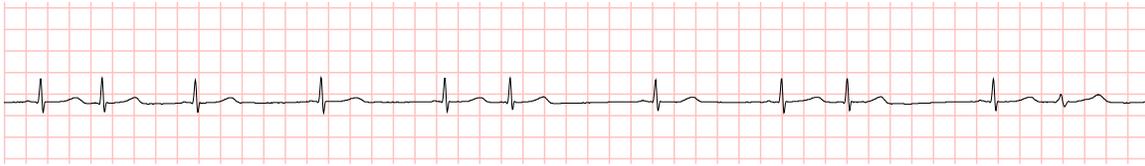


Figura 3. Los detectores conocidos de fibrilación auricular utilizan criterios que hacen de este registro un firme candidato a esa etiqueta. Sin embargo, CONSTRUE() explica apropiadamente los primeros cinco latidos como una bradicardia sinusal, compatible con la presencia de un latido prematuro ectópico en la segunda posición, seguida de un patrón de trigeminismo durante seis latidos, y finalmente otro latido ectópico con un cambio en la morfología. [Fuente: Proyecto Mobiguide, registro privado]

estrategia de modelado del razonamiento que consideramos que forma parte de las funciones cognitivas del ser humano, y que le permiten interpretar el comportamiento de un sistema a partir de los datos disponibles.

Los retos científicos alineados con ambas estrategias son numerosos. En la primera de ellas destaca naturalmente la búsqueda de modelos estocásticos apropiados para series temporales en las que el ruido constituye una componente intrínseca de la dinámica. Siguiendo la aproximación clásica, el objetivo sigue siendo obtener una representación de la dinámica del sistema en el espacio de fases, pero en problemas en los que no se satisface la propiedad de markovianidad asociada a las ecuaciones diferenciales estocásticas usuales, con el fin de modelar procesos caracterizados por una memoria a largo plazo.

Respecto a la segunda de las estrategias planteadas, el reto más relevante es sin duda incorporar el aprendizaje al ciclo hipótesis-test, e integrar así en un mismo esquema formal los tres tipos inferenciales reconocidos por Peirce [14]: deducción, abducción e inducción. La primera forma de incorporación, la más sencilla, consiste en la adaptación dinámica del conocimiento disponible a la evolución particular de la serie temporal, para lo que puede resultar útil un agrupamiento morfológico que evoluciona en el tiempo e incorpora un factor de memoria que determina el compromiso necesario entre plasticidad y estabilidad en función de la capacidad de cambio del sistema [17]. Una segunda forma de incorporación del aprendizaje ha de permitir ampliar el modelo de interpretación con nuevos patrones de abstracción que se pueden proponer como respuesta a determinados errores en la cobertura que proporciona un modelo de interpretación sobre la evidencia. Resulta intuitivo pensar que si una morfología de señal sobre el ECG ocupa sistemáticamente el lugar de un latido pero no se reconoce como tal a partir del conocimiento disponible, este conocimiento debe ampliarse para incorporar tal novedad. Por último, una tercera forma de incorporación del aprendizaje debería plantear el descubrimiento de patrones y gramáticas de abstracción en series temporales, sin ningún tipo de supervisión, sólo con la orientación de un conjunto mínimo de principios que organicen la búsqueda, como es la frecuencia de ocurrencia como medida de interés [18], o el patrón mínimo discernible significativo: por ejemplo, en el caso del ECG, la onda o deflexión de la señal, bajo una restricción de amplitud mínima para ser manifestación de algún fenómeno fisiológico.

## REFERENCIAS

- [1] World Health Organization, "WHO methods and data sources for country-level causes of death 2000-2015", 2017.
- [2] G. Begg, K. Willan, K. Tyndall, C. Pepper, M. Tayebjee, "Electrocardiogram interpretation and arrhythmia management: a primary and secondary care survey," *British Journal of General Practice*, vol. 66, no. 646, pp. e291–e296, 2016.
- [3] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C. K. Peng, H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215–e220, 2000.
- [4] Y. H. Hu, S. Palreddy, W. J. Tompkins, "A patient-adaptable ECG beat classifier using a mixture of experts approach," *IEEE Transactions on Biomedical Engineering*, vol. 44, no. 9, pp. 891–900, 1997.
- [5] D. Castro, P. Félix, J. Presedo, "A method for context-based adaptive QRS clustering in real time," *IEEE Journal of Biomedical and Health Informatics*, vol. 19, no. 5, pp. 1660–1671, 2015.
- [6] G. Moody, R. Mark, "The impact of the MIT-BIH Arrhythmia Database," *IEEE Eng. Med. Biol. Mag.*, vol. 20, no. 3, pp. 45–50, 2001.
- [7] M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt, L. Sörmmo, "Clustering ECG complexes using Hermite functions and self-organizing maps," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 7, pp. 838–848, 2000.
- [8] X. A. Vila, F. Palacios, J. Presedo, M. Fernández-Delgado, P. Félix, S. Barro, "Time frequency analysis of heart rate variability," *IEEE Engineering in Medicine and Biology Magazine*, vol. 16, no. 5, pp. 119–126, 1997.
- [9] C. A. García, A. Otero, P. Félix, J. Presedo, D. G. Márquez, "Simultaneous estimation of deterministic and fractal stochastic components in non-stationary time series," *Physica D: Nonlinear Phenomena*, vol. 374–375, pp. 45–57, 2018.
- [10] T. Penzel, G. Moody, R. Mark, A. Goldberger, J. Peter, "The apnea-ECG database," in *Computers in Cardiology*, pp. 255–258, 2000.
- [11] C. A. García, A. Otero, P. Félix, J. Presedo, D. G. Márquez, "Non parametric estimation of stochastic differential equation with sparse gaussian processes," *Physical Review E*, vol. 96, no. 2, pp. 022104, 2017.
- [12] T. Teijeiro, P. Félix, "On the adoption of abductive reasoning for time series interpretation," *Artificial Intelligence*, Aceptado, 2018.
- [13] J. R. Josephson, S. G. Josephson, *Abductive inference. Computation, philosophy, technology*. Cambridge University Press, 1994.
- [14] C. Hartshorn et al. *Collected papers of Charles Sanders Peirce*. Harvard University Press, 1931.
- [15] T. Teijeiro, P. Félix, J. Presedo, D. Castro, "Heartbeat classification using abstract features from the abductive interpretation of the ECG," *IEEE Journal of Biomedical and Health Informatics*, vol. 22, no. 2, pp. 409–420, 2018.
- [16] T. Teijeiro, C. A. García, D. Castro, P. Félix, "Arrhythmia classification from the abductive interpretation of short single-lead ECG records," in *Computing in Cardiology*, pp. 1–4, 2017.
- [17] D. G. Márquez, A. Otero, P. Félix, C. A. García, "A novel and simple strategy for evolving based clustering," *Pattern Recognition*, vol. 82, pp. 16–30, 2018.
- [18] M. R. Álvarez, P. Félix, P. Cariñena, "Discovering metric temporal constraint networks on temporal databases," *Artificial Intelligence in Medicine*, vol. 58, pp. 139–154, 2013.



**I Workshop de  
Grupos de Investigación  
Españoles de IA  
en Biomedicina  
(IABiomed 2018)**

SESIÓN 2







# Hacia un indicador temprano de Deterioro Cognitivo válido como herramienta de screening

Rafael Martínez-Tomás, Mariano Rincón-Zamorano,  
Alba Gomez-Valadés  
Dpto. Inteligencia Artificial, Universidad Nacional de  
Educación a Distancia  
UNED  
Madrid, Spain

Héctor Gómez, Susana Arias  
Facultad de Ciencias Humanas y Educación  
Universidad Técnica de Ambato  
Ambato, Ecuador

**Abstract**—Las enfermedades neurodegenerativas son causantes de deficiencias cognitivas que disminuyen gravísimamente la calidad de vidas de pacientes y familiares, se han convertido en uno de los problemas más graves de la sociedad actual, cada vez más envejecida. En esta tipología de enfermedades, la identificación temprana, en los primeros estadios, puede aliviar y ralentizar el desarrollo de las mismas. Si bien, para alguna de estas enfermedades (ej. Alzheimer), existen ya indicadores tempranos claros, es importante contar con un mecanismo barato, rápido, poco intrusivo y eficiente para la identificación temprana. En este artículo se resumen los principios y resultados de nuestra investigación con este objetivo. Hemos trabajado con test neuropsicológicos, de producción semántica y gráficos, obteniendo resultados prometedores. También hemos experimentado con la disociación entre la orientación del contenido semántico/emocional oral y la expresividad que le acompaña, en este caso tonalidad, en su articulación. Por último, describimos nuestro trabajo en pro de una mejor integración de resultados de experimentos en estas áreas, que proceden de diferentes fuentes y en diferentes formatos, gracias al diseño de un marco ontológico que sin duda colaborará en una mayor reutilización de estos datos para análisis más completos y profundos.

**Palabras clave**—MCI, neuropsychological test, Alzheimer disease, machine learning, computer vision, bayesian networks.

## I. INTRODUCCIÓN

Se estima que para el año 2020, 48,1 millones de personas en todo el mundo sufrirán problemas relacionados con el síndrome clínico que denominamos demencia [1] y se triplicará para 2050<sup>1</sup>. Quizá por el alargamiento de la esperanza de vida, la enfermedad de Alzheimer (AD), que representa ya la primera causa de demencia neurodegenerativa [2], es el problema más preocupante y analizado de los últimos años relacionado con este síndrome. Es una patología degenerativa causante de deterioro cognitivo y de problemas de comportamiento y funcionales, que no solo produce un alto impacto en la calidad de vida del paciente sino también de sus familiares y cuidadores. AD se está atacando desde múltiples perspectivas, por un lado, buscando terapias para retardar la

evolución neurodegenerativa, y por otro, buscando su detección precoz. Desde el diagnóstico temprano se puede prestar un mayor apoyo al paciente, monitorizar la enfermedad y administrar los tratamientos que permitan mantener su calidad de vida durante más tiempo. Además, como en todos los procesos neurodegenerativos, en un ciclo virtuoso, cuanto antes se diagnostique, mejor se puede estudiar la evolución y consecuentemente conocer mejor la enfermedad.

El mejor y más temprano indicador de la enfermedad de Alzheimer es el índice de concentración de las proteínas tau y beta-amiloide en el fluido cerebroespinal, pero requiere de un método invasivo, la punción lumbar, muchas veces contraindicado. En general, el diagnóstico del deterioro cognitivo puede ser costoso temporal y económicamente, pues requiere la evaluación de información procedente de diferentes fuentes (neuropsicológica, test de laboratorio, neuroimagen, datos históricos, demográficos, personales, etc.) y cuya precisión y eficiencia vienen determinadas por el nivel de pericia del personal profesional. Por su lado, la evaluación neuropsicológica se ha revelado como una herramienta esencial para la detección temprana de deterioro cognitivo, permitiendo identificar déficits funcionales consecuencia de alteraciones en el entramado neuronal producido por enfermedades neurodegenerativas. El DSM-5, la 5ª edición del Diagnostic and Statistical Manual of Mental Disorders del 2013 de la American Psychiatric Association, define seis dominios de la función cognitiva: atención compleja, función ejecutiva, aprendizaje y memoria, lenguaje, función visoespacial y cognición social, cada uno con un determinado número de subdominios.

Nuestro grupo ha utilizado técnicas y metodologías propias de la Inteligencia Artificial (IA) para el análisis de estas evaluaciones neuropsicológicas con el objetivo de obtener herramientas para el screening de población, es decir, herramientas para la identificación temprana de la deficiencia cognitiva, poco invasivas, económicas y sin riesgos secundarios. En concreto, hemos utilizado modelado ontológico para estructurar el conocimiento disponible y poderlo utilizar en inferencia, redes bayesianas para combinar conocimiento de expertos con aprendizaje a partir de datos, y diferentes métodos de aprendizaje automático cuando el volumen de datos lo ha permitido.

<sup>1</sup> <https://www.ceafa.es/es/que-comunicamos/noticias/la-oms-advierte-que-para-el-2050-se-triplicara-la-cifra-de-personas-que-padecen-demencia>

Para conseguir este fin, hemos formado un equipo multidisciplinar en el que participan investigadores del Dpto. de Inteligencia Artificial y del Dpto. de Psicología Básica de la UNED, el Centro de Referencia de la Enfermedad de Alzheimer (CREA) de Salamanca y el Dpto. de Geriátrica del Hospital de Zamora. Asimismo, colaboramos con el grupo dirigido por Dr. Héctor Gómez de la Universidad de Ambato, la residencia del perpetuo socorro de Quito y otros centros asistenciales de Ecuador, y asimismo varios hospitales universitarios noruegos.

En este artículo hacemos un repaso por nuestros trabajos más relevantes en esta línea, y describimos las técnicas empleadas y los resultados obtenidos. En el apartado 2 se describe nuestro trabajo en dos tipos de test neuropsicológicos. Primeramente, mostramos nuestro trabajo en el análisis de la producción oral de categorías semánticas mediante el uso de redes bayesianas (BNs), lo que permite combinar conocimiento experto con el corpus de datos disponible. A continuación, nos centramos en otro tipo de test, también muy habitual en la evaluación cognitiva, que se fundamenta en la copia a mano alzada de figuras geométricas esquemáticas. Aquí, para el análisis, se hace uso de técnicas de visión artificial y aprendizaje automático. En el apartado 3, describimos nuestro trabajo para la identificación de déficits expresivos que puedan asociarse con deterioros cognitivos, para lo cual se analiza la orientación semántica/emocional de la conversación y la correspondiente entonación, buscando inconsistencias en las asociaciones mediante diferentes técnicas de aprendizaje automático. Ya en el apartado 4, se presenta otra línea de trabajo, en la cual utilizamos modelado ontológico para crear herramientas de apoyo a la investigación en consonancia con la tendencia actual de los proyectos de investigación en neurociencia -proyectos multidisciplinarios, heterogéneos y multicentro-, dónde la compartición de datos y la accesibilidad son cruciales. Por último, en el apartado de conclusiones, resumimos los logros obtenidos, los problemas encontrados y las limitaciones de nuestras implementaciones, extrayendo conclusiones generales y futuras líneas de investigación.

## II. APOYO A LA IDENTIFICACIÓN TEMPRANA DEL DETERIORO COGNITIVO DESDE TEST NEUROPSICOLÓGICOS

Los test neuropsicológicos (Neuro-Psychological tests, NPT) se han mostrado muy útiles en la evaluación de los diferentes dominios y subdominios de la función cognitiva mediante la realización de tareas estandarizadas [4], pero es un tema de debate si unas tareas determinadas son las mejores [5], y, por tanto, qué test o combinación de ellos, y qué medidas para su evaluación, permiten clasificar tipologías y determinar etapas del desarrollo del deterioro con más precisión. El debate, parece claro que incluye una dosis de subjetividad [6] [7] y también de propiedad intelectual (test con propiedad intelectual). También existe una inercia a seguir utilizando los mismos test para facilitar la comparativa con otros estudios y para mantener la metodología en estudios longitudinales. En todo caso, hay un consenso generalizado en que los NPTs son una herramienta que, con unos requerimientos muy simples (un papel y un lápiz en algunos casos), es fundamental para determinar claves de la organización de la actividad cerebral y su implicación en los trastornos cognitivos. La lista de test

podría optimizarse o acortarse, con el objetivo de reducir costes económicos y de tiempo, de cara a su aplicación en campañas de screening en amplios sectores de la población.

### A. Análisis de la producción oral con Redes Bayesianas

En [8,9], asumimos que un método de diagnóstico temprano del AD, basado en el análisis de la producción oral para identificar el deterioro de la memoria semántica, era un método que cumplía con nuestros objetivos: es un método simple, barato, y accesible a la población general y sirve como un primer filtro para test posteriores más caros y precisos. Además, nuestra hipótesis era que las BNs eran la herramienta apropiada para alcanzar este objetivo, ya que combinan el conocimiento a priori de los expertos (modelo cualitativo de la BN, su estructura) con el conocimiento aprendido de los conjuntos de datos de casos resueltos (modelo cuantitativo de la BN, probabilidades a priori).

En esta investigación, hicimos uso de dos fuentes de información para el diseño cuantitativo de la BN. Por un lado, el corpus de definiciones orales de Peraita y Grasso [10], que proporciona información sobre las diferencias en la producción semántica entre las personas sanas y los pacientes con CI (diagnosticados como AD leve y moderado). Peraita y Grasso analizaron las características semánticas de las definiciones del corpus, clasificando las definiciones de los pacientes dentro de 11 bloques conceptuales básicos: taxonómicos, tipos, partes funcionales, evaluativos, lugar/habitat, comportamiento, causas/generaciones procedimientos, ciclo de vida y otros. El test consistía en describir seis conceptos, pertenecientes a dos categorías semánticas diferenciales, criaturas vivas y artefactos, contar el número de elementos producidos por cada individuo para cada bloque conceptual y usar este número para obtener probabilidades a priori. Los autores del corpus detallaron los resultados de los casos recopilados (81 personas procedentes de diferentes hospitales de Madrid, 42 sanas y 39 diagnosticadas con AD leve o moderado) y analizaron cómo ciertas categorías semánticas eran representadas mentalmente, empleando modelos teóricos de características semánticas obtenidas de las tareas lingüísticas explícitas.

Por otro lado, el estudio epidemiológico de Fernández et al. [11] relacionó edad, sexo y nivel educativo con AD, lo que nos permitió relacionar la producción lingüística con el deterioro cognitivo (CI) y los estudios epidemiológicos con el AD y, debido a que el CI es un indicador temprano del AD, relacionar el CI con AD. Así, combinando esas dos fuentes pudimos cuantificar la influencia de las variables del modelo.

Se desarrolló una aplicación software en Java para gestionar todo el proceso de adquisición de datos para la BN. La inferencia bayesiana fue implementada a través de los módulos de inferencia desarrollados en Elvira<sup>2</sup>. Entrenamos nuestra red BN con nuestro modelo de aprendizaje propio, empleando como *gold estándar* el diagnóstico llevado a cabo por los neurólogos, quienes seguían los Criterios NINCDS-ADRDA del Alzheimer. Dado el pequeño número de casos disponibles en el corpus, se empleó validación cruzada leave-one-out para evaluar el modelo. La curva ROC obtenida se

<sup>2</sup> Actualmente denominado Open Markov: <http://www.openmarkov.org>



podía usar para estimar el punto de corte óptimo de acuerdo al compromiso entre verdaderos positivos y falsos positivos. Dado que el objetivo era el diagnóstico temprano del AD, lo ideal sería que el sistema detectara todos los casos de AD, aunque el número de personas sanas clasificadas como AD fuera alto. De esta forma, el umbral óptimo en la distribución de probabilidad posterior continua sería aquella que maximizara el número de verdaderos positivos y mantuviera el número de falsos positivos lo suficientemente bajo; sin embargo, para obtener el umbral óptimo, hubiera sido necesario un análisis de coste que quedó fuera del trabajo. Por ello, consideramos nuestra BN como otro método para apoyar el diagnóstico del AD junto a otros test complementarios, y seleccionamos el punto de corte óptimo como el punto de la curva ROC con la máxima precisión. La Tabla 1 muestra las métricas de rendimiento para este umbral.

TABLE I. MÉTRICAS DE RENDIMIENTO OBTENIDAS CON LA BN PROPUESTA

Performance Metrics	Values
TP rate, TP/(TP + FN)	0.8718
FP rate, FP/(FP + TN)	0.0476
Precision, TP/(TP + FP)	0.9444
Accuracy, (TP + TN)/(P + N)	0.9136
AUC, area under ROC curve	0.9621

El estudio concluyó con la confirmación de las ventajas del modelo BN y, por lo tanto, consideramos que son los modelos más adecuados para los sistemas de diagnóstico y para el estudio de la enfermedad a partir del análisis de la producción oral de las características semánticas. Concluimos que:

- El modelo de BN, su estructura y sus parámetros, es reconocible por el experto.
- El modelo cuantitativo puede ser ajustado a partir de una base de datos de casos y estudios, permitiendo, por tanto, la recopilación tanto el conocimiento del experto como del conocimiento implícito en los datos disponibles.
- El modelo de BN, junto al algoritmo de aprendizaje automático, puede ser empleado con otro conjunto de categorías semánticas, tan amplio como sea posible o deseado (lógicamente, el corpus debe poseer los casos suficientes).

Además, este método podría ser extendido con nuevas herramientas para proporcionar una gran cantidad de conocimiento sobre el deterioro de la memoria semántica irregular y contribuir al diagnóstico temprano de una forma extremadamente económica y accesible:

- Se podrían incorporar nuevas variables a nuestro modelo de BN, por ejemplo, variables sociodemográficas y clínicas asociadas, donde la cooperación entre equipos multidisciplinarios podría ser esencial.
- Nuestro sistema podría ser ampliado con un mecanismo de explicación, para lo cual sería especialmente útil medir la sensibilidad del modelo a los cambios en las evidencias.
- Nuestro método puede ser ampliado con análisis de decisiones (diagramas de influencia) para maximizar la utilidad esperada de varias opciones abiertas en la decisión.

Por ejemplo, podría maximizarse la utilidad esperada de las recomendaciones para hacer un test neuropsicológico concreto o exploraciones complementarias como los análisis bioquímicos, PET, etc.

- Disponer de más casos permitiría un análisis más profundo y seleccionar las variables más discriminantes para reducir el tiempo de los test.

#### B. Estudio de los test neuropsicológicos gráficos empleando visión artificial y aprendizaje automático.

Una parte de las pruebas neuropsicológicas estandarizadas diseñadas para evaluar el deterioro cognitivo leve (MCI) incluyen la reproducción o copia de figuras geométricas (test neuropsicológicos gráficos, G-NPT). La idea principal de este método es que ciertas distorsiones respecto a los patrones pueden indicar diferentes grados y perfiles de MCI. Además, no solo se puede evaluar la distorsión respecto al patrón, sino también la evolución en el proceso de ejecución a lo largo de los años. Existen figuras de este tipo en distintos test, como el Mini Examen Cognoscitivo (MEC) [12], el Test Barcelona [13] o la figura compleja de Rey [14].

Los procesos y funciones cognitivas —dominios cognitivos— que supuestamente se evalúan durante la ejecución de esas figuras son la función ejecutiva, la percepción visual y/o visoespacial, las habilidades motrices y la memoria especial. En cada uno de esos procesos o funciones, los rasgos o componentes (control, inhibición, planificación, etc.) involucrados en los patrones a analizar pueden ser definidos, por ejemplo, siguiendo las indicaciones del Dr. Peña Casanova con respecto a los dibujos de gráficos alternantes y bucles.

Mientras que en otros tipos de pruebas estandarizadas que evalúan la memoria episódica, la fluencia verbal, etc. es mucho más fácil obtener datos normativos para puntuar las pruebas sin subjetividad, en estos test que involucran la reproducción y copia de figuras, es mucho más difícil, imponiéndose la subjetividad y cierta discrecionalidad por parte del evaluador. Aunque existe un criterio de evaluación, existe también un gran componente de subjetividad que puede socavar la fiabilidad si las discrepancias entre evaluadores no son corregidas [15]. Como resultado, puede haber un importante margen de error en la detección de ciertos problemas de habilidades motrices, percepción visual o visoespacial, etc. dentro de un entorno para la detección temprana de MCI.

En [16] utilizamos técnicas de visión artificial y aprendizaje automático para automatizar este análisis. Aunque el objetivo a largo plazo era trabajar con todas las figuras de las pruebas mencionadas anteriormente, aquí nos centramos en la figura “pico-meseta”, que es una de las subpruebas del Test Barcelona. El valor diagnóstico de esta prueba, seleccionada para este análisis exploratorio automático, se basa en el hecho de que en su ejecución están involucrados algunos componentes de la función ejecutiva, como la serialización, la planificación, la flexibilidad, la inhibición, así como la capacidad práxica. La tarea consiste en copiar una figura en la que se alternan picos y mesetas. Las distorsiones que pueden emerger en la ejecución de esta figura pueden ser de diferentes tipos: variaciones en el tamaño de la figura realizada, alteración

de las características por la adición o eliminación, garabateo, perseveraciones, rotaciones, acercamiento al patrón, etc. Esos errores o alteraciones en la reproducción del dibujo pueden ser marcadores de disfunciones más severas, que pueden ser de tipo apráxico, en los cuales las funciones ejecutivas también están involucradas, como en la demencia tipo Alzheimer [17].

Dependiendo de los resultados obtenidos en varios NPTs, los participantes fueron clasificados de acuerdo a dos perfiles cognitivos, individuos sanos (n=16), aquellos con puntuaciones normales dentro de las escalas de referencia, e individuos con MCI (n=24). Se desarrolló un algoritmo de visión artificial para 1) segmentar el dibujo, 2) extraer las líneas del dibujo, 3) reconocer los componentes del patrón (picos y mesetas), 4) caracterizar el dibujo y las discrepancias dibujo-patrón (15 características relacionadas con la posición respecto al patrón, diferencia de tamaño, inclinación del dibujo, fallos en el patrón pico-meseta, etc.) y 5) finalmente, establecer un diagnóstico mediante un clasificador implementado con un árbol de decisión J48. El clasificador obtuvo una precisión de 0.77 y una exhaustividad de 0.77.

El problema fundamental del diagnóstico del AD a partir del aprendizaje automático, al igual que en la mayoría de los estudios neurológicos, es la ausencia de un conjunto de datos lo suficientemente grande para construir un sistema fiable de diagnóstico. Tenemos que reconocer que, con esta pequeña muestra, solo pudimos concluir que estas características propuestas para el diagnóstico del MCI eran buenas candidatas, pero que por sí solas no permitían distinguir diferentes tipos de MCI. Para trabajos futuros, estamos ampliando la muestra y queremos combinar características de diferentes figuras para mejorar el rendimiento de la clasificación. De esta forma, este trabajo intenta ser un estudio piloto de un trabajo mucho más amplio, en el cual, a partir de los datos longitudinales ya disponibles, podremos realizar diferentes tipos de análisis:

- Análisis longitudinales de controles sanos: comparar, a lo largo de una serie de años, la ejecución de los dibujos de los sujetos de control sanos, para verificar su estabilidad en la realización de las figuras.

- Análisis longitudinales de los MCIs estables: el mismo tipo de aproximación, pero en otro grupo de sujetos, para intentar responder a las siguientes preguntas: ¿Es la ejecución de las figuras estable? ¿De todas ellas? ¿Por cuánto tiempo?

- Análisis longitudinales de los MCIs que evolucionan bien a AD bien otra demencia.

- Análisis transversales de diferentes tipos de MCI: estudios de grupo con MCI amnésico, multidominio y no amnésico.

- Relación entre la ejecución de la figura y la apraxia ideomotora: para estudiar la relación entre la ejecución de las figuras y la apraxia ideomotora obtenida por los mismos sujetos en otros test.

- Análisis sociodemográficos: para analizar las relaciones entre las variables sociodemográficas, tales como la edad, el género o el nivel educativo, y la ejecución de los patrones de las figuras mencionadas anteriormente.

Pero, por otro lado, los G-NPTs sufren de la ambigüedad inherente a la valoración por diferentes especialistas, tanto en las características significativas de los dibujos como de la clasificación del paciente según el resultado de la misma. Para tratar este problema parece adecuado la aplicación de técnicas de IA, para tratar con las ambigüedades de forma más natural, coherente con la interpretación humana, evitando tomar decisiones "crisp" (según la teoría de conjuntos clásica), por ejemplo, con técnicas difusas o probabilistas.

Sobre determinados G-NPTs, el uso de técnicas de ML ha demostrado altos niveles de precisión, pero se ha trabajado sobre cada test de forma independiente por la incertidumbre en la asociación dibujo-patrón. Hay muchos tipos y es necesaria una asociación de los G-NPTs con las capacidades cognitivas y motoras, y de estas con regiones y dinámica cerebral. Se echa de menos la definición de ontologías que los modelen, organicen y enlacen.

### III. ANÁLISIS DEL DÉFICIT DE EXPRESIVIDAD USANDO ANÁLISIS DE SENTIMIENTO

En [18] planteamos la hipótesis de que el contenido semántico/emocional del discurso y las manifestaciones físicas asociadas (gestos, entonación...) se alinean en personas cognitivas normales, pero no en aquellas personas afectadas por la demencia. Por ello, planteamos este elemento para identificar pacientes con problemas cognitivos en la etapa inicial.

El estudio de cambios de comportamiento, analizado con resultados favorables a partir de texto escrito en personas mayores [19], podría ayudar a prevenir enfermedades ligadas a dichos cambios. El análisis de la voz se ha usado para indicar signos de la enfermedad en ancianos [20]. Nosotros tomamos en cuenta la semántica de una conversación y la emoción en la tonalidad de la voz conjuntamente, en vez de por separado, para verificar si el contenido semántico-emocional del texto de un entrevistado correlaciona con el tono de voz. Si no están relacionados, podríamos suponer que se debería avisar a los familiares o cuidadores acerca de los cambios en el comportamiento del paciente.

Para el análisis, seleccionamos dos características asociadas con la semántica de un texto: la polaridad y la orientación semántica. La polaridad (positiva, negativa o neutra) está basada en diccionarios especializados y usamos la herramienta *SentiStrength*<sup>3</sup> para medirla. La orientación semántica es una medida propuesta por [26] que ayuda a clasificar frases como "Excelente" o "Pobre". La orientación semántica funciona con las opiniones que las personas tienen acerca de las palabras o frases en un contexto predeterminado. Se busca esta orientación en frases similares mediante Google<sup>4</sup> Api.

Las variaciones de la entonación que una persona le da a una frase mientras habla se asocia con variaciones emocionales. Para ello se usó la herramienta *Speech Recognition System*<sup>5</sup>. De aquí, la emoción de la voz se puede

<sup>3</sup> <http://sentistrength.wlv.ac.uk/>

<sup>4</sup> <http://ajax.googleapis.com/ajax/services/search/web?v=1.0&q=%s>

<sup>5</sup> <https://www.linkedin.com/pulse/speech-emotion-recognition-system-matlab-source-code-luigi-rosa>



comparar con la polaridad y con la orientación ya que se clasifican dentro de bandas positivas -excelentes y negativas-pobres. Nos ha interesado especialmente el análisis e interpretación de los datos, más que la investigación en las técnicas de extracción de características.

Las entrevistas (texto+audio) del grupo de control, formado por pacientes ancianos sanos, se obtuvo de Charlotte<sup>6</sup>. Los resultados mostraron que no había una gran variabilidad entre los valores etiquetados por los expertos y las herramientas empleadas. No se obtuvo disociación entre polaridad, orientación semántica y entonación. Después se probó con pacientes con AD en una etapa temprana y sí se obtuvo disociación relevante ( $p$ -valor $<0,05$ ). Los valores obtenidos de polaridad, orientación semántica y entonación utilizaron para construir varios clasificadores que distinguieran entre personas sanas y AD. Los clasificadores se probaron con variables individuales y combinadas, proporcionando mejores resultados para el F1Score cuando se trabajó con las 3 variables simultáneamente. Los resultados demuestran que es posible utilizar el método para el diagnóstico, y que las variables trabajan mejor juntas que cuando son usadas por separado en los clasificadores.

TABLE II. COMBINING SENTI-STRENGTH-PMI-TONALITY

Algorithm	Precision	Recall	F1Score
J48	0,88	0,78	0,83
Multilayer perceptron	0,75	0,86	0,80
Bayes Net	0,79	0,91	<b>0,85</b>

#### IV. UN MARCO SEMANTICO INCREMENTAL PARA MEJORAR LA ACCESIBILIDAD EN SISTEMAS BIOBANKING

Como ha quedado patente a lo largo del artículo, uno de los problemas con el que nos encontramos es la falta de una muestra significativa para los estudios. Por ello, es fundamental poder integrar *datasets* de distintos estudios, con muy diferentes características y contextos. El intercambio y accesibilidad de los datos permite unir los esfuerzos entre diferentes grupos de investigación, así como en los estudios de replicación, cruciales para el progreso en el campo. Las soluciones de los archivos de datos de investigación están evolucionando rápidamente para abordar esas necesidades, sin embargo, la integración de los datos distribuidos es todavía complicada debido a la necesidad de acuerdos entre los diferentes modelos de datos. Para abordar estos problemas, las ontologías son ampliamente empleadas en investigación biomédica para obtener vocabularios comunes y descripciones lógicas, pero su aplicación podría sufrir de problemas de escalabilidad, sesgos de dominio, y pérdida de acceso de los datos de bajo nivel. Con el objetivo de mejorar los modelos de aplicación semántica en los sistemas de *biobanking*, hemos diseñado e implementado un marco semántico incremental que aprovecha los últimos avances en ontologías biomédicas y en la plataforma XNAT [21]. Se trata de una aproximación metodológica para abordar el problema de habilitar modelos basados en la semántica en sistemas de archivos de investigación ya implementados. Esto mejora la gestión de los

<sup>6</sup> <http://newsouthvoices.uncc.edu/nsv/southernpiemont>

datos, desde datos de bajo nivel a conceptos semánticos y lógicos. Construido con tecnologías de la Web Semántica y empleando ontologías biomédicas, el marco proporciona un modelo homogéneo de acceso a datos y razonamiento sobre datos neurológicos multimodales.

El diseño del marco sigue una aproximación de abajo a arriba por capas, permitiendo trabajar con los datos a diferentes niveles de descripción. El marco añade capacidades de razonamiento a partir de las relaciones implícitas y las definiciones lógicas para derivar nuevos datos, y realiza comprobaciones de coherencia de los datos para el Control de Calidad. El empleo de los principios de enlazado de datos permite el enlace entre datos, abriendo las puertas a conjuntos de datos externos de referencia. Además, el tener un conjunto de datos altamente enlazados facilita la inspección desde diferentes conceptualizaciones (proyecto, tema, enfermedad, etc.), una característica altamente deseable para el descubrimiento de patrones y el estudio de las relaciones entre enfermedades a medida que el conjunto de datos crece.

Nuestra propuesta se diferencia de trabajos anteriores en que se centra en las consultas y el razonamiento avanzados sin perder los datos de bajo nivel, mientras aprovecha las ventajas de las plataformas de archivos ya disponibles y ampliamente utilizadas. En particular, elegimos XNAT como la columna vertebral para el manejo de los datos y las imágenes clínicas, debido a su amplio conjunto de características y su diseño flexible y personalizable.

Este marco está siendo utilizado en el JPND (EU Joint Program for Neurodegenerative Disease)<sup>7</sup>/APGeM project<sup>8</sup>, destinado a encontrar biomarcadores tempranos para la enfermedad de Alzheimer y otras demencias relacionadas [22] Comprende una cantidad significativa de datos de diferentes subdominios y modalidades, como neuroimágenes, bioquímica, rastreos clínicos/ neuropsicológicos y genéticos, estableciendo un escenario adecuado para impulsar y probar el marco en el curso de la investigación neurológica actual.

#### V. CONCLUSIONES

El problema de identificar etapas tempranas de enfermedades neurodegenerativas se puede atacar desde múltiples perspectivas. Aunque hemos experimentado con el déficit de la producción gestual en personas con demencia, este factor, medido en nuestro trabajo mediante la disociación entre gesto, tonalidad, y contenido semántico-emocional del discurso, no nos sirve como indicador neuropsicológico temprano de la enfermedad porque características subjetivas, como la motivación, la depresión, el estrés o simplemente el estado de ánimo, pueden hacer que personas sanas presenten signos de disociación semejantes.

Por eso nos estamos centrando más en identificar el deterioro cognitivo mediante test neuropsicológicos, que han demostrado ser una solución rápida y económica en la que vale la pena emplear recursos. Hemos investigado en la automatización y evaluación automática de diferentes

<sup>7</sup> <http://www.neurodegenerationresearch.eu/>

<sup>8</sup> <http://www.neurodegenerationresearch.eu/publication/apgem/>

mecanismos, el test de producción oral y test gráficos. Hay otros test, como el test de fluidez verbal, que aportan conclusiones diferentes y que tendrán que ser analizados en detalle y, seguramente, automatizados en próximos trabajos.

En cualquier caso, cada día se incrementa de manera no lineal la cantidad de datos de historias clínicas almacenadas, por lo que resulta natural que los nuevos trabajos de investigación traten de concentrar toda esta información. La manera de investigar está cambiando desde una investigación individualista, en la que es necesario proponer un modelo que explique o que sea consistente los pocos datos disponibles conocidos, hacia un modelo cooperativo, en el que los estudios multicentro, multidisciplinares, multidimensionales y heterogéneos, serán lo habitual, y el modelado del conocimiento y el aprendizaje automático a partir de datos cobrará cada vez más importancia. Para ello, como muestra el último trabajo presentado, es fundamental un marco ontológico que oriente la integración de diferentes fuentes, formatos de datos y resultados, para un mejor aprovechamiento en experimentos más completos y profundos, que ayuden a conocer mejor la enfermedad y su afectación sobre funciones cognitivas y áreas cerebrales.

#### RECONOCIMIENTOS

- Proyecto 018-ABEL-CM-2013, financiado por el programa NILS Science and Sustainability con el The Intervention Centre del Oslo University Hospital
- Ayuda predoctoral PEJD-2017-PRE/TIC-4406 cofinanciada por la UNED y el Fondo Social Europeo a través del Programa Operativo de Empleo Juvenil y la Iniciativa de Empleo Juvenil.

#### REFERENCES

[1] M. Prince, R. Bryce, E. Albanese, A. Wimo, W. Ribeiro and C.P. Ferry. "The global prevalence of dementia: a systematic review and metaanalysis". *Alzheimer's & Dementia*, vol. 9(1), pp.63-75, 2013.

[2] H.W. Querfurth and F.M. La Ferla. "Alzheimer's disease". *The New England Journal Medicine*, vol. 362, no. 4, pp. 329-344, 2010.

[3] S. G. Gauthier. "Alzheimer's disease: the benefits of early treatment". *European Journal of Neurology*, vol. 12(s3), pp.11-16, 2005.

[4] M.D. Lezak. *Neuropsychological assessment*. Oxford University Press, USA, 2004.

[5] G. Gainotti, D. Quaranta, M.G. Vita and C. Marra. "Neuropsychological predictors of conversion from mild cognitive impairment to Alzheimer's disease". *Journal of Alzheimer's Disease*, vol. 38(3), pp. 481-495, 2014.

[6] H.C. Fichman, R.M. Oliveria and C.S. Fernandez. "Neuropsychological and neurobiological markers of the preclinical stage of Alzheimer's disease". *Psychology & Neuroscience*, vol. 4(2), pp. 245-253, 2011.

[7] R.H. Logie, M.A. Parra and S. Della Salla. "From cognitive science to dementia assessment". *Policy Insights from the Behavioral and Brain Sciences*, vol. 2(1), pp. 1-91, 2015.

[8] J.M. Guerrero, R. Martínez-Tomas, M. Rincon and H. Peraita. "Diagnosis of Cognitive Impairment Compatible with Early Diagnosis of Alzheimer's Disease". *Methods of information in medicine*, vol. 55(1), pp. 42-49, 2016.

[9] J.M. Guerrero, R. Martínez-Tomas and H. Peraita. "Bayesian Network Based Model for the Diagnosis of Deterioration of Semantic Content Compatible with Alzheimer's Disease". *Foundations on Natural and Artificial Computation. Lecture Notes on Computer Science*, vol 6686, pp.461-470, Springer, 2011

[10] H. Peraita and L. Grasso. *Corpus lingüístico de definiciones de categorías semánticas de personas mayores sanas y con la enfermedad de Alzheimer: una investigación transcultural hispano-argentina*. Fundación BBVA, 2010.

[11] M. Fernández-Martínez, J. Castro-Flores, S. Pérez-delas-Heras, A. Mandaluniz-Lekumberri, M. Gordejuela and J. Zarranz. "Prevalencia de la demencia en mayores de 65 años en una comarca del País Vasco". *Revista de Neurología*, vol. 46 (2), pp. 89-96, 2008.

[12] A. Lobo, J. Ezquerro, J., F. Gómez, J.M. Sala, A. Seva. "El mini-examen cognoscitivo. Un test sencillo, práctico, para detectar alteraciones intelectivas en pacientes médicos". *Actas Luso Españolas de Neurología, Psiquiatría y Ciencias Afines* vol. 3, pp. 189-202, 1979.

[13] J. Peña-Casanova. Programa integrado de exploración neuropsicológica "test Barcelona". In *Normalidad, semiología y patología neuropsicológica*. Masso, Barcelona, 1991.

[14] A. Rey. Rey. Test de copia y de reproducción de memoria de figuras geométricas complejas. TEA, Madrid, 2003)

[15] S. Urbina. Claves para la evaluación con tests psicológicos (Kaufman, A.S., Kaufman, N.L (trad.)). TEA Ediciones (publicado originalmente en 2004), Madrid, 2007.

[16] M. Rincón, Sara García-Herraz, M.C. Díaz-Mardomingo, R. Martínez-Tomás & H. Peraita. Automatic drawing analysis of figures included in neuropsychological tests for the assessment and diagnosis of mild cognitive impairment. In *International Work-Conference on the Interplay Between Natural and Artificial Computation*, pp. 508- 515. Springer, Cham. 2015.

[17] R.Q. Freeman. T. Giovannetti, M. Lamar, B.S. Cloud, R.A. Stern, E. Kaplan, D.J. Libon. "Visuoconstructional problems in dementia: contribution of executive systems functions". *Neuropsychology* vol. 14(3), pp. 414-426, 2000.

[18] S. Arias, R. Martínez-Tomas, H. Gómez, V. Hernandez, J. Sanchez, J. Barbosa, J. Mocha. The dissociation between polarity, semantic orientation, and emotional tone as an early indicator of cognitive impairment. *Frontiers in Computational Neurosciences*, vol. 10 (95), 2016.

[19] H. Cole-Lewis, T. Kershaw. "Text Messaging as a Tool for Behaviour Change in Disease Prevention and Management." *Epidemiology*, nº 10.1093, 2010.

[20] L. Naranjo, C. Pérez, Y. Campos-Roca and J. Martín. "Addressing Voice recording replications for Parkinson's disease detection". *Expert Systems with Applications* vol. 46, pp. 286-292, 2015.

[21] S. Timon, M. Rincón, R. Martínez-Tomás. "Extending XNAT Platform with an Incremental Semantic Framework". *Frontiers in Neuroinformatics*. vol 11, art. 5, 2017.

[22] T. Fladby, L. Pålhaugen, P. Selnes, K. Waterloo, G. Bråthen, E. Hessen. "Detecting at-risk alzheimer's disease cases". *Journal of Alzheimer's Disease*. Vol. 60(1), pp. 97-105, 2017.



# eXiT Research Group at the University of Girona: Artificial Intelligence and Machine Learning Applied to Medicine and Healthcare

Beatriz López, Natalia Mordvanyuk, Joaquim Massana, Ferran Torrent-Fontbona, Gerard Cáceres, Carles Pous

*eXiT research group*

*University of Girona*

{beatriz.lopez,natalia.mordvanyuk}@udg.edu, quim.massana@hotmail.com,  
ferran.torrent@udg.edu, gerardgi96@gmail.com, carles.pous@udg.edu

**Abstract**—This paper describes the research activity of the eXiT research group at the Universitat of Girona and the main results achieved. The research is organized in four main groups: prognosis, clinical decision support systems, mHealth, and biosignal processing. The paper describes past, current and future research of the group.

**Index Terms**—Case-based reasoning, Personalization, Patient monitoring, Resource optimization.

## I. INTRODUCTION

Research group eXiT (Control Engineering and Intelligent Systems) focuses its work on decision support systems, case-based reasoning, machine learning and optimization. There are two main labs in the group and one of them, Medicine and Healthcare lab, is dedicated to Medicine and Healthcare and focuses on the incorporation of intelligent systems and biomedical engineering in health management and on the development of innovative medical technologies.

The research activity on eXiT Medicine and Healthcare lab (eXiT for short from now on) starts around 2005, when the Foundation Hospital Dr. Josep Trueta becomes a research institution and synergies between the hospital's researchers and the University staff pop up.

As a result of eXiT's research activity, several awards were conceded: Best Paper in the 2014 IMIA Yearbook of Medical Informatics for the work 'Enabling the use of hereditary information from pedigree tools in medical knowledge-based systems', ITEA Excellence Awards 2015 for the MEDIMATE project, 2nd prize in the Vall d'Hebron Research Institute (VHIR) Innovation Healthcare Contest for the NoaH project, and the ITEA Vice-chairmans award for SME Success in the MOSHCA project. Moreover, eXiT has been awarded since 1995 by the regional government with quality labels (current label: 2017 SGR 1551). Another important outcome is the

This project has received funding from the European Unions Horizon 2020 research and innovation programme under grant agreement No 689810 (PEPPER). Work developed with the support of the awarded distinction by the Generalitat de Catalunya 2017 SGR 1551, the MESC project funded by the Spanish MINECO (Ref. DPI2013-47450-C21-R), and the University of Girona grant to supporting research groups to improve their scientific productivity (MPCUdG2016).

eXiT\*CBR tool (<http://exitcbr.udg.edu/>), which is available to all of the researchers.

An overview of the different application domains in which eXiT has been working on is shown in Figure 1. In the next sections, the applications are described and grouped according to the problems addressed: prognosis (purple color in Figure 1), Clinical Decision Support Systems (CDSS, green), mHealth (blue), biomedical signal processing (orange) and healthcare services (garnet). Some future applications (black) are commented at the end of the paper.

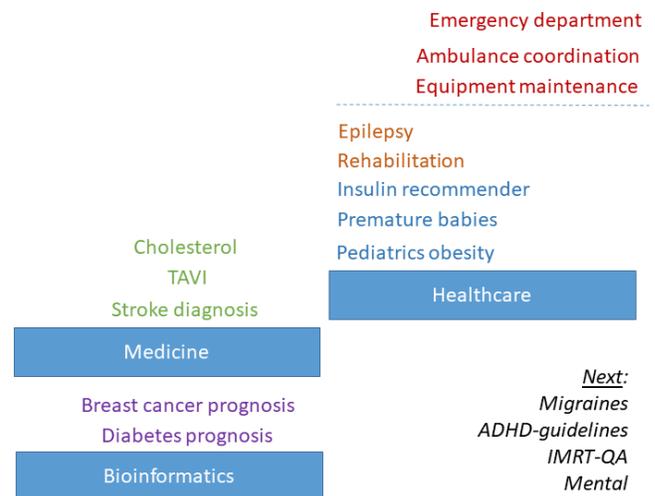


Fig. 1. Overview of application domains. Coloured applications described in this paper: Purple: Prognosis; Green: Clinical Decision Support Systems; Blue: mHealth; Orange: biomedical signal processing; Garnet: Healthcare services; Black: future research.

## II. PROGNOSIS

Artificial Intelligence (AI) and Machine Learning (ML) methods have been applied to prognosis for two risk diseases: breast cancer and Type 2 Diabetes Mellitus (T2DM).

### A. Breast Cancer

We were facing the following prognosis problem: generate a breast cancer risk model from a dataset of 871 cases (628 healthy women and 243 women with breast cancer). The core technology used was case-based reasoning (CBR, [1], [10]).

Instead of developing a dedicated system, we opted to build a generic tool, eXiT\*CBR [15], [27], which provided some key features for Medicine, such as the importance of experiment repetition and the need to interact with clinicians showing the results in plots that were easy to interpret for them.

The main techniques used include the particular methods to implement the basic steps of the CBR methodology (i.e. similarity metrics, cases selection), as well as evaluation techniques (e.g. cross-validation), metrics (e.g. precision, recall), and plots (e.g. ROC-plots). eXiT\*CBR also includes some plug-ins and pre-processing steps, one of them related to the acquisition of inheritance data from families, which has been awarded by the International Medical Informatics (*IMIA Best paper in 2014*, [7]).

In a second stage, the need for improving the results of the first prototype led us to include additional features into the second version of eXiT\*CBR: multi-agent management (enabling physicians in a joint prognosis) [23], multi-criteria decision making (as a consequence of the first one) [14], feature learning with the use of genetic algorithms [16], and subgroup discovery [11].

The medical research team of such joint research are members of the Catalan Institute of Oncology (Joan Brunet, Judith Sanz, Teresa Ramon y Cajal). The funding received for this research was provided by the Girona Biomedical Research Institute ("Family history as a model for evaluation breast cancer risk"), and the University of Girona (eXiTDM: Data Mining Platform).

### B. Type 2 Diabetes Mellitus

In this case, we dealt with the problem of building a model for T2DM prognosis. The starting point was 1074 subjects with and without T2DM, which included both, clinical data (IMC, sex, age) and up to 112 polymorphisms (insulin-like growth factor binding protein, CD36 antigen, adiponectin receptor 2, etc.).

The methods applied were dimensionality reduction with PCA, i.e. regular simplex PCA which is adequate for discrete data, and personalized prediction with CBR. The achieved success ratio was around 89% with 5 principal components [26].

The research was carried out with the endocrinologist Dr. J.M. Fernandez-Real of the Girona Biomedical Research Institute (IdiBGi). This work was made possible by the support of the Spanish MEC project DPI2005-08922-C02-02, the IdiBGi project GRCT41, and DURSÍ AGAUR SGR 00296 (AEDS).

## III. CLINICAL DECISION SUPPORT SYSTEMS

One of the first works on CDSS developed by eXiT was for acute stroke classification. Acute strokes are medical emergencies that require from an expert neurologists in order

to detect the illness in the appropriate therapeutic time window. Thanks to the development of new treatments, like the rt-Pa treatment, mortality rates have been descending in the last decades. However, the final diagnosis of the patients is often imprecise, and from it depends the administration of new treatments. That is, a patient can have a diagnosis of acute stroke, but the clinical category of it is often unknown. This situation has been detected by the Spanish Association of Neurologists, which has set up a repository of cases named Badisen. Using this database, we have designed a multi-agent case based system with the aim of giving support in the acute stroke diagnoses. An agent in the system keeps information of experiences in a single hospital, maintaining the particular decision criteria employed by the main physician. Agents collaborate in a lack of confidence in the initial diagnosis, thanks to a trust mechanism [17]. The medical team includes Dr. Serena from the Hospital Dr. Trueta of Girona.

The second problem addressed was a workflow-based CDSS designed to give case-specific assessment to clinicians during complex surgery or minimally invasive surgery. Following a perioperative workflow, the designed software uses the CBR methodology to retrieve similar past cases from a case base to provide support at any particular point of the process. The graphical user interface allows easy navigation through the whole support progress, from the initial configuration steps to the final results, organized as sets of experiments easily visualized in a user-friendly way. As a result, the eXiTCDSS tool was developed [5]. This work has been performed in the context of the MEDiate European Project (Eureka ITEA 2 no 09039 -TSI-020400-2010-84) with several clinical teams involved and the key collaboration of *Hospital Clinic de Barcelona*.

Finally, we are currently finalizing HTE 3.0, a CDSS for lipid-lowering treatment and familial hypercholesterolemia detection [2]. In that case, the main AI technique used is rule based reasoning combined with a three-layer decision chain: risk analysis, treatment personalization, and safety and cost-effectiveness criteria. The work has been carried out with Dr. A. Zamora of the *Corporació de Salut del Maresme i La Selva*. HTE 3.0 has been registered at the Intellectual Property Register of Girona, ref UdG - Reg GI2532016 - Web CDSS HTE 3.0., and it has been sponsored by Sanofi.

## IV. MHEALTH: MONITORING AND PERSONAL RECOMMENDATIONS

One of the key challenges in modern Medicine is to provide individualized assessments to patients [3]. In this regard, precision Medicine is looking for genetics particularities in order to provide the appropriate treatment to patients. However, other ICT approaches that deal with personalized responses to the users, taking into account their particular history and context, are also dealing with such challenge. CBR has been proven to be a useful technique for providing adapted and personalized recommendations. eXiT\*CBR has been used with this purpose in two case scenario: care of premature babies at home and insulin dose recommendations. Moreover, from the



collaboration with a pediatric team, a project for promoting healthy habits in obese kids was developed.

#### A. *Premature Babies at Home*

Nowadays women give birth to healthy babies, but sometimes premature due to their advanced age during pregnancy. That means many newborns should stay several weeks in the hospital intensive care units until they reach a safe weight. However, recent studies have shown that premature babies develop faster if they stay at home, in a familiar environment, instead of at the hospital. Thus, several hospitals have started to discharge babies at home, in special hospital programs, where a nurse attends once or twice per week the family by visiting the baby at home.

In order to improve the monitoring of such babies, reduce the stress of parents, and dedicate nursing personnel especially to critical cases, the NoaH platform was developed (see Figure 2). The medical team involved was headed by Dr. Abel López-Bermejo (pediatric doctor of Hospital Dr. Trueta of Girona) in cooperation with Dra. Eva Bargallo and Dra. Cristina Armero, both neonatologists, and supported by Dra. Judith Bassols. This work has been carried out in the context of the MOSCHA European project (EUREKA ITEA 2 n 11027 IPT-2012-0943-300000).

The NoaH platform has two main components: a mobile component and a server component. The mobile part is managed by the parents, and it is connected to a pulsi-oximeter used to read vital signs of the baby. Once a day parents place the sensor to the baby and input to a dedicated mobile application some other information such as baby's weight, number of intakes, depositions, sleep, etc. Thanks to a hybrid system composed by a rule-based system (with general medical knowledge) and a CBR system (with particular knowledge of baby's history), the parents receive an assessment about the child: normal, warning, alert. This information is sent through the NoaH platform to the clinical server, where the clinical staff revises it.

The CBR methodology helps to avoid false positives by considering information about the baby's history. For example, a rule could say that a baby should gain 10gr weight per day, but a baby is doing around 8gr per day. If the daily gain is consistent with her history, the system will not trigger any warning [12]. Furthermore, in order to take advantage of the computing capabilities of mobile phones, context aware reasoning was also considered [24].

The NoaH platform was tested in a controlled scenario (in hospital) with a successful feedback from users and it is in the process of being deployed in practice. Moreover, it was awarded in 2015 with the second prize in the Vall d'Hebron Research Institute (VHIR) Innovation Healthcare Contest and it has been finalist in the mHealth category of the Summer Competition of the Universite de la Sante, Castres, France.

#### B. *Insulin Bolus Recommender System*

The burden of diabetes has led to dedicate a huge amount of research efforts to improve the quality of life of people

that suffer the disease, as well as, to minimize the impact on healthcare systems. In this context, the PEPPER project [9] proposes the development of an ICT platform to follow up people with T1DM and recommending them the insulin dose to administer in ingests events with the use of a recommender mobile app. The platform has two main components: a mobile part and a server component. Analogous to NoaH, the mobile part is addressed to citizens, in this case people with T1DM, while the server component is designed to be managed by the clinical staff.

The mobile component is attached to two sensors: a continuous glucometer that measures the blood glucose level, and a wrist band that provides information about the physical activity of the user. Moreover, the outcome (insulin dose), could be sent to an insulin pump for its infusion. Thus, there are two scenarios considered in PEPPER: multiple daily injections with insulin pen (MDI architecture in Figure 3), and insulin pump (CSII architecture in Figure 3). In this latter case, after the system recommendation is validated by the user, the dose is automatically sent to the pump and administrated to the user.

Regarding the recommendations provided in the mobile component, the use of CBR enables a personal and adapted answer to the user throughout time. PEPPER CBR methodology has been implemented using eXiT\*CBR, however, the following new functions were added to it to meet PEPPER requirements: numerical reuse, revise step and maintenance step, which includes retain, review and restore, capable of tackling concept drift. The first task addressed was the numeric reuse, as the solution of the CBR methodology is a numeric parameter used to calculate the needed insulin dose [29]. Second, the CBR methodology of eXiT\*CBR was extended by including a revise step and a maintenance phase, as proposed in [19], in order to correct proposed solutions given their outcome and then analyze the convenience of incorporating new experiences to the knowledge base and deleting old ones. Thus, these steps enable the system to learn from its continuous use.

Maintenance methods, according to [19], include two additional stages in the CBR methodology: review and restore. In the review stage, the case base is analyzed looking for obsolete data, according to what is known as concept drift [6], [20]: changes in concepts. In the particular case of T1DM management, people can suffer physiological changes so that solutions that have been right two months ago, could not be longer valid. As a consequence, in the restore stage, cases no longer valid (or labeled to be discarded due some review metrics) are removed from the case base [30].

The medical team involved in the decisions made in the development of the new functions includes all the clinical staff of the PEPPER project (<http://www.pepper.eu.com/>).

Regarding the PEPPER insulin recommender system, it has been tested with the UVA/PADOVA simulator [21], achieving successful results as reported in [29] and [28]. It will be validated soon with real users in the context of the PEPPER project.

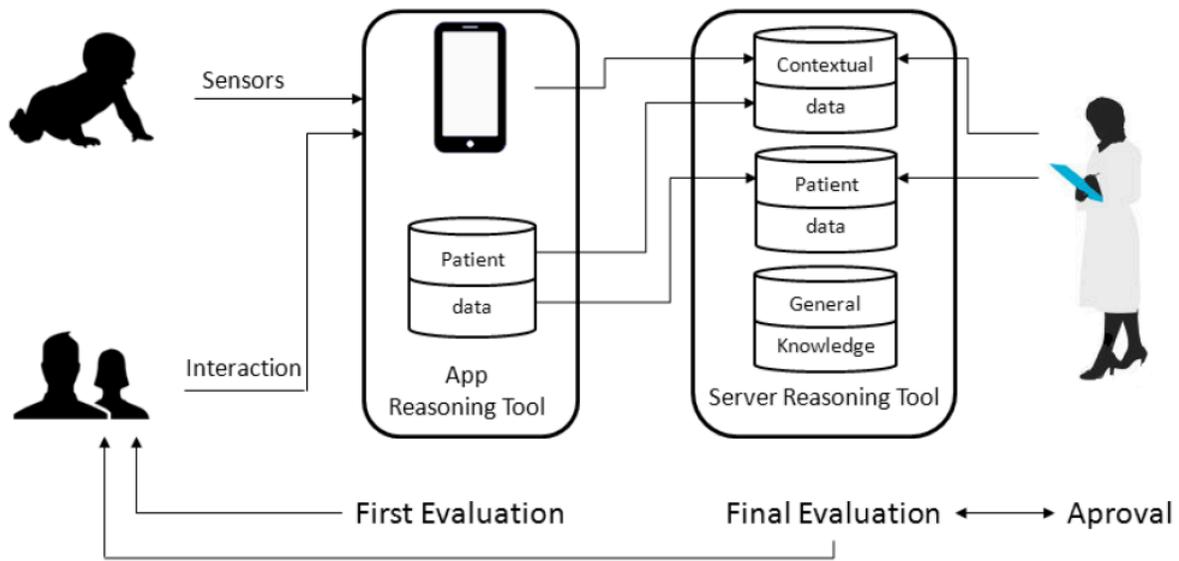


Fig. 2. Simplified architecture of NoaH from [24].

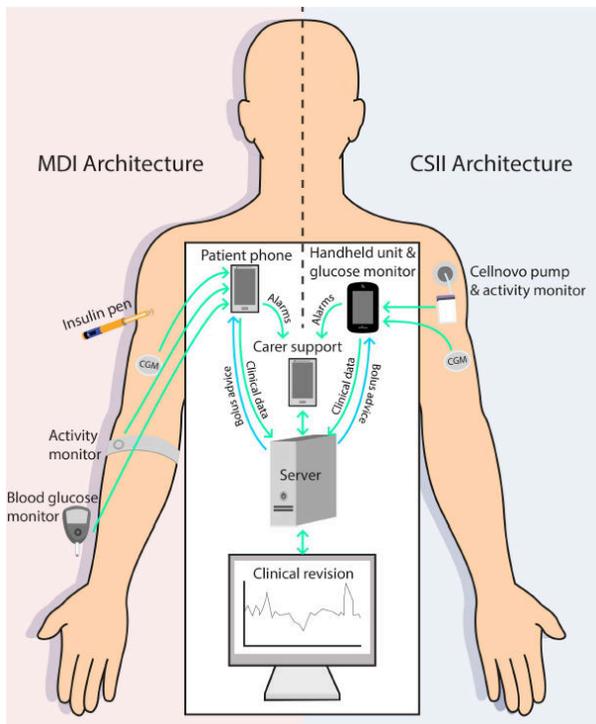


Fig. 3. Pepper architecture from [9].

### C. Healthy kids

Having care of our kids today is the best bid we can make to have a healthy society tomorrow. However, three main diseases threaten kids' health: obesity, diabetes and asthma. While parents are conscious that diabetes and asthma are serious

diseases, it seems that they are less aware about the harm of obesity. To address obesity issues, we develop MATCHuP, a tool to enhance good nutrition and exercise habits with the aim to reduce both, obesity and diabetes, known as metabolic diseases. MATCHuP platform is focused on people with metabolic diseases and their families to improve their education in the right habits. MATCHuP recommends actions connected to the patients' community using collaboration strategies to simplify input validation and competition incentives, to award the user with gaming. Dr. Abel Lpez-Bermejo from the Hospital Dr. Trueta of Girona supervised the research [18].

### V. BIOSIGNAL PROCESSING

The appearance of new wearable and non-invasive sensors is providing new and disruptive solutions for the monitoring of patients, disease management and treatment adherence [22]. In fact, the mHealth applications described in the previous sections make use of wearables: NoaH uses a pulsi-oximeter, PEPPER uses a continuous glucometer and an activity wristband, and MATCHuP also uses wrist bands for monitoring kids' activity. However, there are new opportunities, new sensors that could be investigated for Medicine and Healthcare. This is the case of force sensors, for rehabilitation purposes, and portable EEG, for epilepsy seizure detection.

First, we worked in collaboration with the Evalan company in the context of the MOSCHA European project (EUREKA ITEA 2 n 11027 IPT-2012-0943-300000) and the Rehabilitation team of Dr. Herman R. Holstlag, Marco Raaben and Taco J. Blokhuis. The company developed sandal shoes with force sensors, in order to monitor patient gaits. In particular, people who have undergone hip surgery. The gait analysis provides



information about the people who recovered in the expected time and people who had a slow recovery or never returned to a normal situation. Therefore, we dealt with a classification problem (good versus bad recovery). The input signal, first was processed with a bag-of-steps methodology, and then support vector machine and CBR were used for classification purposes [25].

A EEG wearable has been created by the MJN Neuroserveis company (<http://mjn.cat/>), and eXiT is studying the application of AI and ML techniques. This collaboration is subject to a confidential agreement.

## VI. HEALTHCARE SERVICES

In this section we have included the research related to the management of services, as ambulance coordination, medical equipment maintenance, and emergency attendance forecasting.

### A. Ambulance coordination

Ambulance services can be grouped in two main categories: emergency and programmed services. Regarding emergency services, they need to guarantee that persons with urgent treatment are attended in less than 15 minutes, independently of the distance to the nearest medical centre they are. To that end, we developed a multi-agent system, which includes fuzzy filters [13]. The system has been tested with the data provided in the Girona region, in collaboration with Quim Llorella and Rosa Prez (SEM services) who share with us the details of the real emergency transportation service. The work has been supported by the Spanish MEC (Ministerio de Educacin y Ciencia) project TIN2004-06354-C02-02.

Regarding the second category, programmed patient transport, the problem consists on providing, in a daily basis, a 24h scheduling to non-urgent ambulances in regard to their task of moving patients from home (or residences) to hospitals in order to receive a particular treatment; and next, provide an on-line scheduling to return them back home. To that end, we develop an ambulance coordination software module which has been transferred to the Lafcarr company under the name IrisAmb.

It is interesting to highlight that the research activity developed on ambulance coordination, especially on optimization methods, led to the creation, in 2011, of Newronia S.L., an spin-off company (<http://en.newronia.com/>). It is devoted to provide AI based solutions to optimize resources related to transportation and logistics.

### B. Medical Equipment Maintenance

Hospitals are having a growing burden on the management of medical equipment. To support them, two works have been carried out by eXiT: workflow monitoring for equipment repair, and fault prediction of complex medical equipment. First, workflow monitoring was proposed to follow-up the equipment repair status: expensive equipment had always the highest priority, and causes that less expensive one be never repaired. To implement the solution, we used Petri nets

for workflow modeling and complex event processing (CEP) for workflow monitoring to predict possible delays [8]. The research was conducted inside the AIMES European project (Eureka ITEA2 07017, TSI-020400-2008-047) in collaboration with the University Hospital Magdeburg.

In the second case, we were dealing with a complex equipment, with several components that provide individual log reports. The aim was to predict the global, complex equipment failures as a combination of the information provided in the different individual logs. Therefore, we were dealing with longitudinal data. We use sequence learning methods to learn sequential patterns, and next apply CBR for failure forecasting [4]. The work has been carried out under a confidential contract with a multinational company.

### C. Emergency attendance forecasting

Hospital patient waiting times and length of stay are indicators of the quality of emergency department (ED) services. It is necessary to accurately estimate ED patient arrivals in order to manage resources effectively. In the particular case of a Tourist region, this estimation is difficult due to the population variability. To that end, we collaborated with the ED of the Hospital of Palamós, placed in a tourist region, with a high population variability. We have tested several regression methods for attendance forecasting at different time horizons, and using some exogenous variables as calendar and weather data <sup>1</sup>.

## VII. CONCLUSIONS

The eXiT research group has a long track of works in the Biomedical and Healthcare fields. This paper summarizes the main activities in these fields during the last years.

Future research include new application domains. First, regarding CDSS, we have been recently awarded with a project regarding attention-deficit hyperactivity disorder treatment recommendations, which is headed by Dr. D. Serrano and Dr. X. Castells. Second, concerning mHealth, we have an agreement with a private company to work with patients suffering migraines. Third, about biosignal processing, we are initiating some research on mental diseases. And finally, in regard to healthcare services, a PhD work is being conducted about improving the optimization of the plans for intensity-modulated radiotherapy.

## ACKNOWLEDGMENT

Thanks to the eXiT\*CBR team: Albert Pla, Pablo Gay, Jordi Coll, Francisco Gamero, Marc Compta, Jos Antonio Manrique, Daniel Macaya, Alejandro Pozo-Alonso. Thanks to former members of eXiT, and in particular, to the Medicine and Health lab.

<sup>1</sup>Publication is under review

## REFERENCES

- [1] A. Aamodt and E. Plaza. Case-based reasoning: Foundational issues, methodological variations, and system approaches. *AI communications*, 1994.
- [2] Z. Alberto, F. Torrent-Fontbona, B. López, E. Feliu, C. Carrion, M. Aymerich, X. Castells, L. Blanco, A. Martín-Urda, A. Pozo-Alonso, and C. Capellà. Desarrollo, validación en pacientes de alto riesgo vascular y evaluación de un CDSS de ayuda en el tratamiento hipolipemiente (HTE-DLPR). *Revista Española de Comunicación en Salud*, Suplemento:17–18, 2016.
- [3] E. Capobianco. Ten challenges for systems medicine. *Frontiers in genetics*, 3:193, 2012.
- [4] M. Compta and B. López. Integration of Sequence Learning and CBR for Complex Equipment Failure Prediction. In Ram A., Wiratunga N. (eds) *Case-Based Reasoning Research and Development. ICCBR 2011. Lecture Notes in Computer Science, vol 6880.*, pages 408–422. Springer, Berlin, Heidelberg, 2011.
- [5] A. El-Fakdi, F. Gamero, J. Meléndez, V. Auffret, and P. Haigron. eXiTCDSS: A framework for a workflow-based CBR for interventional Clinical Decision Support Systems and its application to TAVI. *Expert Systems with Applications*, 41(2):284–294, feb 2014.
- [6] J. Gama, I. Žliobait, A. Bifet, M. Pechenizkiy, and A. Bouchachia. A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4):1–37, mar 2014.
- [7] P. Gay, B. López, A. Pla, J. Saperas, and C. Pous. Enabling the use of hereditary information from pedigree tools in medical knowledge-based systems. *Journal of Biomedical Informatics*, 46(4):710–720, aug 2013.
- [8] P. Gay, A. Pla, B. López, J. Meléndez, and R. Meunier. Service workflow monitoring through complex event processing. In *Proceedings of the 15th IEEE International Conference on Emerging Technologies and Factory Automation, ETFA 2010*, 2010.
- [9] P. Herrero, B. López, and C. Martin. PEPPER: Patient Empowerment Through Predictive Personalised Decision Support. In *Proc. ECAI Workshop on Artificial Intelligence for Diabetes*, pages 8–9, 2016.
- [10] B. López. *Case-based reasoning: A concise introduction*, volume 20. Morgan & Claypool Publishers, Synthesis Lectures on Artificial Intelligence and Machine Learning, 2013.
- [11] B. López, V. Barrera, J. Meléndez, C. Pous, J. Brunet, and J. Sanz. Subgroup Discovery for Weight Learning in Breast Cancer Diagnosis. In Combi C., Shahar Y., Abu-Hanna A. (eds) *Artificial Intelligence in Medicine. AIME 2009. Lecture Notes in Computer Science, vol 5651*, pages 360–364. Springer, Berlin, Heidelberg, 2009.
- [12] B. López, J. Coll, F.-I. Gamero, E. Bargalló, and A. López-Bermejo. Intelligent systems for supporting premature babies healthcare with mobile devices. In *Mobilmed*, 2013.
- [13] B. López, B. Innocenti, and D. Busquets. A multiagent system for coordinating ambulances for emergency medical services. *IEEE Intelligent Systems*, 23(5), 2008.
- [14] B. López, C. Pous, P. Gay, and A. Pla. Multi Criteria Decision Methods for Coordinating Case-Based Agents. In L. Braubach et al. (Eds.): *MATES 2009, LNAI 5774*, pages 54–65. Springer, Berlin, Heidelberg, 2009.
- [15] B. López, C. Pous, P. Gay, A. Pla, J. Sanz, and J. Brunet. eXiT\*CBR: A framework for case-based medical diagnosis development and experimentation. *Artificial Intelligence in Medicine*, 51(2):81–91, feb 2011.
- [16] B. López, C. Pous, A. Pla, and P. Gay. Boosting CBR Agents with Genetic Algorithms. In In: McGinty, L., Wilson, D.C. (eds.) *ICCB 2009. LNCS (LNAI)*, pages 195–209. Springer, Berlin, Heidelberg, 2009.
- [17] B. Lopez, C. Pous, J. Serena, and J. Piula. Cooperative case-based agents for acute stroke diagnosis. In *ECAI Workshop on Agents Applied in Health Care, Riva di Garda, Italia*, pages 21–28, 2006.
- [18] B. López, S. Soung, N. Mordvanyuk, A. Pla, P. Gay, and A. López-Bermejo. MATCHuP: An mHealth Tool for Children and Young People Health Promotion. In *Proceedings of the 10th International Joint Conference on Biomedical Engineering Systems and Technologies - Volume 5: HEALTHINF, 313-318, 2017, Porto, Portugal*, pages 313–318. SCITEPRESS, 2017.
- [19] R. Lopez de Mantaras, D. McSherry, D. Bridge, D. Leake, B. Smyth, S. Craw, B. Faltings, M. L. Maher, M. T. Cox, K. Forbus, M. Keane, A. Aamodt, and I. Watson. Retrieval, reuse, revision and retention in case-based reasoning. *The Knowledge Engineering Review*, 20(03):215, sep 2005.
- [20] N. Lu, G. Zhang, and J. Lu. Concept drift detection via competence models. *Artificial Intelligence*, 209:11–28, apr 2014.
- [21] C. D. Man, F. Micheletto, D. Lv, M. Breton, B. Kovatchev, and C. Cobelli. The UVA/PADOVA Type 1 Diabetes Simulator: New Features. *Journal of diabetes science and technology*, 8(1):26–34, jan 2014.
- [22] A. Pantelopoulos and N. G. Bourbakis. A survey on wearable sensor-based systems for health monitoring and prognosis. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 40(1):1–12, 2010.
- [23] A. Pla, B. López, P. Gay, and C. Pous. eXiT\*CBR.v2: Distributed case-based reasoning tool for medical prognosis. *Decision Support Systems*, 54(3):1499–1510, feb 2013.
- [24] A. Pla, B. López, N. Mordvaniuk, C. Armero, and A. López-Bermejo. Context Management in Health Care Apps. In *AAMAS Workshop A2HC Agents Applied in Health Care*, page 8 pages, 2015.
- [25] A. Pla, N. Mordvanyuk, B. López, M. Raaben, T. Blokhuis, and H. Holstlag. Bag-of-steps: Predicting lower-limb fracture rehabilitation length by weight loading analysis. *Neurocomputing*, 268, 2017.
- [26] C. Pous, D. Caballero, and B. Lopez. Diagnosing patients with a combination of principal component analysis and case based reasoning. *International Journal of Hybrid Intelligent Systems*, 6(2):111–122, may 2009.
- [27] C. Pous, P. Gay, A. Pla, J. Brunet, J. Sanz, T. R. y. Cajal, and B. López. Modeling Reuse on Case-Based Reasoning with Application to Breast Cancer Diagnosis. In In: Dochev D., Pistore M., Traverso P. (eds) *Artificial Intelligence: Methodology, Systems, and Applications. AIMSA 2008. Lecture Notes in Computer Science, vol 5253*, pages 322–332. Springer Berlin Heidelberg, Berlin, Heidelberg, 2008.
- [28] F. Torrent-Fontbona. Adaptive basal insulin recommender system based on Kalman filter for type 1 diabetes. *Expert Systems with Applications*, 101:1–7, jul 2018.
- [29] F. Torrent-Fontbona and B. Lopez. Personalised Adaptive CBR Bolus Recommender System for Type 1 Diabetes. *IEEE Journal of Biomedical and Health Informatics*, pages 1–1, 2018.
- [30] F. Torrent-Fontbona, J. Massana, and B. Lopez. Case-base maintenance of a personalised bolus insulin recommender system for Type 1 Diabetes Mellitus. In *Proceedings of Joint Workshop on Artificial Intelligence in Health (AIH2018), Stockholm*, pages 22–32. <http://ceur-ws.org/Vol-2142/>, 2018.



# Research on medical decision analysis at the CISIAD, UNED

Francisco Javier Díez   Manuel Luque   Jorge Pérez-Martín   Manuel Arias

*Dept. Artificial Intelligence*

*Universidad Nacional de Educación a Distancia (UNED)*

Madrid, Spain

{fjdiez, mluque, jperezmartin, marias}@dia.uned.es

**Abstract**—The Research Centre for Intelligent Decision-Support Systems (CISIAD) has been doing research on probabilistic graphical models applied to medicine for almost three decades. In this paper we summarise the contributions we have made, analyse the main difficulties we have found, and present the main failures and successes we have had in those years.

**Index Terms**—artificial intelligence, probabilistic graphical model, Bayesian network, influence diagram, Markov model, medical decision making, cost-effectiveness analysis

## I. INTRODUCTION

One of the features of artificial intelligent systems is the ability to draw conclusions in uncertain domains. In medicine uncertainty is ubiquitous, mainly due to limited knowledge about the causal mechanisms and to the non-determinism of the real world. For this reason medicine has been one of the main fields of application since the beginning of artificial intelligence. The first methods for reasoning with uncertainty were based on the theory of probability, more specifically on what we now call *the naïve Bayes method*, which relies on two assumptions: diseases are mutually exclusive and findings are conditionally independent given the diagnosis. With these simplifying hypotheses it was possible to build several models that succeeded in solving several diagnostic problems in the 1960's and 1970's [1]–[6]. However, the assumptions required by this method are usually unrealistic in practice, which led many researchers to assert that probabilistic methods could not be used to solve large AI problems—see [7], [8] for a discussion.

The situation changed significantly in the next decade with the advent of probabilistic graphical models (PGMs). Howard and Matheson, two economists of the Stanford Research Institute (SRI) developed influence diagrams as a compact representation of decision problems, alternative to decision trees [9], and Judea Pearl, an artificial intelligence researcher at UCLA, developed Bayesian networks as an extension of the naïve Bayes [10], [11]. Very soon other authors proposed efficient algorithms for the evaluation of influence diagrams [12], [13] and Bayesian networks [14]. The first PGMs for real-world medical problems were developed in the next years [15]–[18] and the number of applications has grown so fast

afterwards that now it is impossible to have a registry of all the medical applications that use PGMs.

In this paper we review some of the applications developed at the Centre for Intelligent Decision-Support Systems (CISIAD) of the National University for Distance Education (UNED), in Madrid, Spain, summarise the contributions we have made, analyse the main difficulties we have found, and present the main failures and successes we have had in almost three decades of research.

## II. PROBABILISTIC MODELS FOR MEDICAL PROBLEMS

### A. PGMs for medical diagnosis

In 1989 Javier Díez began a doctoral thesis in artificial intelligence for medicine under the supervision of Prof. José Mira at UNED. The topic was the construction of an expert system for echocardiography, in collaboration with some doctors of the Hospital de la Princesa, in Madrid. In those years most expert systems were built using rules, and fuzzy logic was more and more popular. Prof. Mira had supervised several PhD theses that had applied these techniques to different medical problems [19]–[22], so they seemed to be the obvious choice for Díez's thesis. However, in the first knowledge elicitation sessions one of the doctors proposed building a causal network: mitral stenosis causes left atrium hypertension, which back-propagates to the lungs, and so on. However, when Díez tried to encode this causal model into a set of rules, it was impossible, because a piece of knowledge such as “A causes B” can be used either to infer B from A, or vice versa; but rule-based reasoning is unidirectional. Additionally, when A and B are causes of C and C is observed, the presence of A rules out B (this phenomenon is called *explaining away* [10]) and, conversely, discarding A increases the suspicion that B has caused C. Due to these limitations of rule-based reasoning and to his training as a physicist, Díez began exploring probabilistic reasoning for causal models, without being aware of the landmark contributions made by Pearl a few years earlier [10], [11], [23], [24]. He then rediscovered Bayesian networks, the noisy OR gate and its generalization to multivalued variables [25], which he called the noisy MAX [26], [27], and developed a new algorithm for evidence propagation [28]. In 1992 he spent three months at UCLA invited by Judea Pearl, and was able to catch up with the avant-garde of the research in this field, which was led by Pearl's group.

This work has been supported by grant TIN2016-77206-R of the Spanish Government, co-financed by the European Regional Development Fund. J.P. received a predoctoral grant from the Spanish Ministry of Education.

After finishing his doctorate in 1994 [29], Díez supervised several PhD theses that built Bayesian networks for several problems: Carmen Lacave [30], [31] built Prostanet for urology, Severino Fernández Galán [32] built Nasonet for nasopharyngeal cancer and Nuria Alonso Santander [33], an ophthalmologist of Hospital de la Princesa (Madrid), built Catarnet for cataract surgery.

### B. PGMs for decision analysis

Because of our contact with health professionals, we realised that in medicine the final goal is not to issue a diagnosis, but to make decisions. In many cases finding out the disease with the higher probability or obtaining a list of variables whose posterior probability exceeds a certain threshold is not enough, because very often a low probability of a serious disease is more relevant than a high probability for a relatively-benign disease. In fact, newspapers from time to time tell the story of a patient who died after presenting at the urgency room of a hospital and being discharged because the doctors just gave the most likely diagnosis, without taking into account that the symptoms were compatible with an infrequent but mortal disease. Clearly, in medicine a false positive and a false negative have very different costs: the former usually leads to performing additional tests and sometimes starting an unnecessary treatment, which has an economic cost and may cause anxiety and discomfort to the patient, but a false negative may lead to delaying a treatment necessary to save the patient's life.

For this reason we were interested in building models that explicitly took into account the decisions and the cost of tests and treatments, including the cost of giving the wrong treatment or no treatment. This is how we started investigating influence diagrams (IDs), which differ from Bayesian networks in that they do not only have chance nodes, but also decision and utility nodes [9]. During his doctoral work, Manuel Luque built Mediastinet, an influence diagram for the mediastinal staging of non-small cell lung cancer, in collaboration with Dr. Carlos Disdier, of Hospital San Pedro de Alcántara (Cáceres) [34], [35], and Diego León built Arthronet, an influence diagram for total knee arthroplasty, during his master thesis, in collaboration with a doctor of Valladolid [36]. Every influence diagram is equivalent to a decision tree, but IDs have the advantage of being much more compact and, consequently, much easier to build and modify. In particular, both Mediastinet and Arthronet are equivalent to decision trees containing more than 10,000 leaves, and there is an algorithm that can transform each of them into the corresponding tree—provided that the computer has enough working memory.

In these models the main criterion was clinical effectiveness, measured in quality adjusted life years (QALYs), but they also represented the economic cost. In health economics the standard way of combining cost and effectiveness into a single criterion is to compute the net monetary benefit,

$$NMB = \lambda \cdot e - c ,$$

or, alternatively, the net health benefit,

$$NHB = \lambda^{-1} \cdot NMB = e - \lambda^{-1} \cdot c ,$$

where  $e$  is the effectiveness (measured in QALYs or in another clinical unit),  $c$  is the cost (in monetary units, such as dollars or euros) and  $\lambda$ , known as *willingness to pay* or *cost effectiveness threshold*, is a parameter that converts effectiveness into monetary units [37], [38]. This way it was possible to evaluate Mediastinet taking into account just the effectiveness (i.e., disregarding the cost, by making  $\lambda^{-1} = 0$ ) or for specific values of  $\lambda$ . The problem is that  $\lambda$  is different for each decision maker. In Spain most health economists accept  $\lambda = 30,000$  €/QALY as a value of consensus for our public health system, but there are also some experts claiming that this value is too high. Therefore, it would be desirable to perform a true cost-effectiveness analysis (CEA) in order to find out the values of  $\lambda$  (the thresholds) that determine the most beneficial intervention for each decision maker. Unfortunately, the algorithms available ten years ago were only able to perform CEA for decision trees containing just one decision node, at the root, and both Mediastinet and Arthronet had several decisions.

For this reason our group first developed a CEA algorithm for trees with several decisions [39] and then for IDs [40]. After implemented them in OpenMarkov, an open-source software tool that we describe below, it was possible to evaluate these IDs in a few seconds.

However, many medical problems involve asymmetries of several types. There is *order asymmetry* when the decisions are not totally ordered; for example, when it is not clear which test to do first, if any, and what tests to do afterwards depending on the result of previous tests. There may be *information asymmetry* due conditional observability; for example, the result of a test is known only when the doctor decides to perform it. And there is *domain asymmetry* when the value of one variable restricts the values of others; for example, when the decision is not to do a test, its result is neither positive nor negative. In IDs the second and third types of asymmetry can be represented—clumsily—by adding dummy states to some variables, but order asymmetry cannot be represented because IDs require a total ordering of the decisions. With the purpose of overcoming these limitations we proposed decision analysis networks (DANs) [41] and developed a CEA algorithm for them [42].

### C. PGMs for temporal reasoning

In the same way as our collaboration with medical doctors led us from diagnosis (with Bayesian networks) to unicriterion decision analysis and then to cost-effectiveness analysis, it also showed us the importance of temporal reasoning. Our group had proposed two new types of temporal PGMs, namely networks of probabilistic events in discrete time (NPEDTs) [32] and dynamic limited memory influence diagrams (DLIM-IDs) [43]. The former were developed originally to model the spread of nasopharyngeal cancer [44] and the latter to predict the progression of carcinoid tumours [45]. For different



reasons none of these types of networks could solve the typical problems in which health economists are currently interested. Therefore we extended our work on IDs to develop Markov IDs [46]. With them we have been able to conduct CEAs for several medical problems, such as pleural effusion [47], colorectal cancer [47], cochlear implantation [48], etc.

### III. DEVELOPMENT OF OPEN-SOURCE TOOLS

These medical applications have been built with two open-source tools: Elvira and OpenMarkov. Elvira was the result of a collaboration of several Spanish universities, mainly Granada, Almería, Castilla-La Mancha, País Vasco and UNED [49]. The high number of developers, with experienced researchers, was the main reason for its rapid development, with the implementation of many algorithms for inference and learning, but, on the other hand, the physical distance between the teams involved in the project and the lack of adherence to the principles of software engineering made the tool difficult to maintain.

For this reason the UNED started the development of a new tool, called OpenMarkov [50]. We departed from the experience gained with Elvira, but the all the code was written from scratch. It is now a large tool, with around 115,000 lines of Java code, excluding blanks, and more than 200,000 lines in total, organised in 44 maven projects. The fact that it is managed by a single team and the use of several software engineering tools (git, maven, nexus, jenkins, etc.) has allowed us to make several redesign decisions and to maintain the code, which is still growing actively.

Both Elvira and OpenMarkov have advanced graphical user interfaces for editing and evaluating PGMs. Elvira has many learning algorithms, while OpenMarkov only implements the two basic algorithms, namely search-and-score and PC, but in general it is much more robust and more efficient in inference, and offers more types of networks (Markov IDs, DANs, etc.), more options for sensitivity analysis and temporal models, CEA, and the possibility of learning Bayesian networks interactively [51].

To our knowledge, Elvira was used in 10 countries, almost exclusively at universities, while OpenMarkov has been used for teaching, research and developing applications at universities, research centres and companies of more than 30 countries in Europe, America, Asia and Africa.

### IV. DIFFICULTIES, FAILURES AND SUCCESSES

In this section we analyse some of the difficulties we have found when building artificial intelligence applications for medicine, which range from technical challenges to human factors, and describe the main failures and successes we have faced.

#### A. Building PGMs with expert knowledge

Our group differs from most others in the field of PGMs in that, instead of investigating new learning algorithms, we have specialised in building PGMs with expert knowledge. This process is time consuming and, what makes it much

more challenging, requires in general the collaboration of medical doctors. None of the health professionals who have collaborated with us has ever received any economic compensation for their work. Some of them have collaborated actively, but others had a low degree of commitment, to the point that it was difficult for us to arrange the meetings with them. For this reason, some of our attempts to build models for medical problems have failed after having investing a significant amount of time and effort.

#### B. Use of PGMs for clinical decisions

Clinical decision-support systems can be used in at least two ways. One of them is to guide the diagnosis and the treatment of individual patients at the clinical consultation or at the bedside. Many expert systems have been designed for this purpose, including our first PGMs. However, we do not know of any AI system routinely used this way. We were close to succeed with Catarnet, the above-mentioned Bayesian network for cataract surgery. The Health Department of the regional government of Madrid, who had financed the project, was interested in implanting this system into the new big hospitals it manages. We collaborated with the technicians of one of them to design a protocol for integrating Catarnet into their information system. When we were just about to start the tests, there was a change in the leadership of the hospital and the new person responsible refused to implant the decision-support system unless he could obtain from it some benefit for his professional/political career.

AI might also be applied to developing public health policies. However, these policies are based, in the best scenarios, on epidemiological studies, economic evaluations of health technologies and the consensus of experts; there seems to be no room for expert systems. However, in our group we have combined PGMs, an AI technique, with cost-effectiveness analysis, as mentioned above. One of the models we have built is a Markov ID for analysing the cost-effectiveness of paediatric bilateral cochlear implantation (BCI), i.e., for determining whether it is worth putting two implants instead of one to babies who are born with severe to profound deafness. The preliminary study we conducted, which included a thorough review of the literature, contributed to convincing the Ministry of Health that it is cost-effective, and Spain became the first country in the world—to the best of our knowledge—to include BCI for both children and adults in the portfolio of health services (cf. Orden SSI/1356/2015, de 2 de julio). In spite of this law, several regional governments still refuse to cover it in practice, even for newborns. We wrote a detailed report, based on our cost-effectiveness analysis [48], which proved beyond any reasonable doubt that this intervention is clearly cost-effective for children, and submitted it to the Ministry of Health and to 11 regional health departments. In May 2018 the Ministry of Health sent a letter to F. J. Díez in which it explicitly rectified its previous stance and confirmed that BCI must be covered by all health providers in Spain. More recently, Catalonia and Andalusia, two of the regions that had steadfastly refused covering it have announced that

they will start putting two implants to the children that need them. This is the first time that our research on medical AI has had an impact on the life of patients.

We are working on two models for finding the optimal screening patterns for breast cancer and colorectal cancer. Even though there are several studies about these topics, we intend to develop new models and new algorithms for finding the optimal screening pattern for each patient based on his/her personal features. We will soon begin a CEA of screening for cytomegalovirus in newborns; if our study concludes that it is cost-effective, as some experts have recently claimed, health authorities should include it in the battery of tests for neonatal screening, which would have an impact on the life of many children and families.

### *C. A probabilistic expert system for programming cochlear implants*

Our interest for cochlear implants led us to contact Dr. Paul Govaerts, who had been investigating the application of AI to programming them. This is a difficult task, because an implant has more than 100 electronic parameters that can be fitted. Improving the quality of hearing in one setting (for example, in a quiet room) may deteriorate the hearing in others (for example, in a noisy street). He had built a rule-based system that improved the performance of human audiologists, but the results were far from impressive. For this reason he started a new project, financed by a EU grant, aimed at building a new version of the expert system. A prestigious research group specialised in machine learning joined the project as a partner. However, some technical problems made it impossible to obtain the data they counted on, and even with them it would have been virtually impossible to build a model using learning algorithms, due to the complexity of the task. Seeing that the project had run aground, Dr. Govaerts contacted our group. The combination of his knowledge of audiology and cochlear implant technology with our expertise in building PGMs from human knowledge made it possible to create a probabilistic model based on a causal graph and subjective estimates of the probabilities [47], [52], [53]. In a few months it gave the first useful results and two years later impressed some experts in Europe and the USA for its performance. The main manufacturer of cochlear implants, who has a market share of more than 50%, has bought the rights to exploit it exclusively.

## V. CONCLUSIONS AND FUTURE WORK

Our group has been doing research on artificial intelligence applied to health decision making for almost three decades. We have contributed new algorithms [28], [39], [40], [42], [50], [54]–[61], new types of probabilistic graphical models (NPEDTs [32], DLIMIDs [43], [45], tuning networks [52], Markov IDs [46], DANs [41]), new canonical models [26], [27], [52] and several methods for the explanation of reasoning [62]–[66]. Each of them was motivated by a specific medical problem for which we were building a probabilistic network, but all of them can be applied to other domains. Similarly,

the software tools we have developed [49], [50] are designed mainly for medicine, but other groups have used them to build applications in very different fields. These software tools have also been very useful for teaching PGMs to our students [67], [68].

Looking retrospectively, we can see that our efforts to build decision-support systems for clinical consultation have failed far from obtaining the benefits we expected. Building a probabilistic model manually takes a lot of time and requires the commitment of medical doctors, who in some cases collaborate enthusiastically but in others are poorly motivated and abandon the project far before arriving at the goal. Similarly, we have invested lots of time in developing software tools with advanced graphical user interfaces, in spite of our scarcity of funding and human resources. These tools have been very useful for our research and teaching, and also for many other universities in four continents. Several institutes and large companies of different countries have used OpenMarkov to build real-world applications. This has brought us the personal satisfaction of having offered the AI community a useful tool, but so far we have not obtained any economic return from it, and in the academic world, governed by the “publish or perish” principle, it is a risk to devote much time to tasks that yield poor results in terms of journal papers. Sometimes we ask ourselves if we made a mistake by following these lines of research instead of working on other areas, such as machine learning, in which the productivity is much higher.

Nonetheless, our research has also brought us other rewards. We have been pioneers in the application of AI to cost-effectiveness analysis, which is more and more relevant for medical decision making. Our economic study of cochlear implantation has contributed to convincing the Spanish health authorities that profoundly deaf people should receive two cochlear implants instead of one, especially in the case of children. Our experience in building probabilistic models from human knowledge and our software tool, OpenMarkov, had been essential in the construction of an expert system that is routinely used for programming cochlear implants; given that there are hundreds of thousands of cochlear implant users in the world, we are happy to know that our work will contribute to improving the quality of life of so many people. This tool is superior in several aspects to the commercial products developed for this task—and also inferior in others, clearly—and even though it is open-source, there are several possibilities of obtaining monetary returns from it: distributing it under dual-licensing, offering consultancy (mainly to pharmaceutical companies and manufacturers of medical devices), doing under-contract developments, etc. We are currently exploring these possibilities in order to obtain financial resources for our research activity.

### *Acknowledgements*

We thank our colleagues and friends who collaborated in the Elvira project, from whom we learnt so much, and all the students and former members of our group who have collaborated in the development of OpenMarkov. We also thank



the reviewers of the First Workshop of Spanish AI Research Groups in Biomedicine, at the CAEPIA-2018 conference, for their corrections and suggestions.

## REFERENCES

- [1] F. T. de Dombal, J. R. Leaper, J. R. Staniland, A. McCann, and J. Horrocks, "Computer-aided diagnosis of acute abdominal pain," *British Medical Journal*, vol. 2, pp. 9–13, 1972.
- [2] G. A. Gorry, "Computer-assisted clinical decision making," *Methods of Information in Medicine*, vol. 12, pp. 45–51, 1973.
- [3] G. A. Gorry and G. O. Barnett, "Experience with a model of sequential diagnosis," *Computers and Biomedical Research*, vol. 1, pp. 490–507, 1968.
- [4] J. Habbema, "Models for diagnosis and detection of combinations of diseases," in *Decision Making and Medical Care*, F. de Dombal and F. Gremy, Eds. New York: North-Holland, 1976, pp. 399–411.
- [5] H. R. Warner, A. F. Toronto, and L. G. Veasy, "Experience with Bayes' theorem for computer diagnosis of congenital heart disease," *Annals of the New York Academy of Sciences*, vol. 115, pp. 558–567, 1964.
- [6] H. R. Warner, A. F. Toronto, L. G. Veasy, and R. Stephenson, "A mathematical approach to medical diagnosis: Application to congenital heart disease," *Journal of the American Medical Association*, vol. 177, pp. 177–183, 1961.
- [7] P. Szolovits, Ed., *Artificial Intelligence in Medicine*. Boulder, CO: Westview Press, 1982.
- [8] P. Szolovits and S. G. Pauker, "Categorical and probabilistic reasoning in medicine," *Artificial Intelligence*, vol. 11, pp. 115–144, 1978.
- [9] R. A. Howard and J. E. Matheson, "Influence diagrams," in *Readings on the Principles and Applications of Decision Analysis*, R. A. Howard and J. E. Matheson, Eds. Menlo Park, CA: Strategic Decisions Group, 1984, pp. 719–762.
- [10] J. Pearl, "Fusion, propagation and structuring in belief networks," *Artificial Intelligence*, vol. 29, pp. 241–288, 1986.
- [11] —, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Mateo, CA: Morgan Kaufmann, 1988.
- [12] S. M. Olmsted, "On representing and solving decision problems," Ph.D. dissertation, Dept. Engineering-Economic Systems, Stanford University, CA, 1983.
- [13] R. D. Shachter, "Evaluating influence diagrams," *Operations Research*, vol. 34, pp. 871–882, 1986.
- [14] S. L. Lauritzen and D. J. Spiegelhalter, "Local computations with probabilities on graphical structures and their application to expert systems," *Journal of the Royal Statistical Society, Series B*, vol. 50, pp. 157–224, 1988.
- [15] S. Andreassen, M. Woldby, B. Falck, and S. K. Andersen, "MUNIN — a causal probabilistic network for interpretation of electromyographic findings," in *Proceedings of the Tenth International Joint Conference on Artificial Intelligence (IJCAI'87)*, J. P. McDermott, Ed. Milan, Italy: Morgan Kaufmann, 1987, pp. 366–372.
- [16] R. F. Nease and K. D. K. Owens, "Use of influence diagrams to structure medical decisions," *Medical Decision Making*, vol. 17, pp. 263–275, 1997.
- [17] K. G. Olesen, U. Kjærulff, F. Jensen, F. V. Jensen, B. Falck, S. Andreassen, and S. K. Andersen, "A MUNIN network for the median nerve. a case study on loops," *Applied Artificial Intelligence*, vol. 3, pp. 385–403, 1989.
- [18] D. K. Owens, R. D. Shachter, and R. F. Nease, "Representation and analysis of medical decision problems with influence diagrams," *Medical Decision Making*, vol. 17, pp. 241–262, 1997.
- [19] R. Marín, "Un sistema experto para el diagnóstico y tratamiento anteparto del estado materno-fetal," Ph.D. dissertation, Universidad de Santiago, Santiago de Compostela, 1987.
- [20] R. Marín, M. Taboada, J. Mira, A. Barreiro, and R. P. Otero, "Design and integration of a graphic interface for an expert system in oncology," *International Journal of Biomedical Computing*, vol. 33, pp. 25–43, 1993.
- [21] R. P. Otero, "Medtool: Una herramienta para el desarrollo de sistemas expertos," Ph.D. dissertation, Universidad de Santiago, Santiago de Compostela, 1991.
- [22] R. P. Otero and J. Mira, "Medtool: A teachable medical expert system development tool," in *Proceedings of the Third International Symposium on Knowledge Engineering*, Madrid, Spain, 1988, pp. 191–200.
- [23] J. Pearl, "Reverend Bayes on inference engines: A distributed hierarchical approach," in *Proceedings of the Second National Conference on Artificial Intelligence (AAAI'82)*, D. L. Waltz, Ed. Pittsburgh, PA: AAAI Press, 1982, pp. 133–136.
- [24] J. H. Kim and J. Pearl, "A computational model for combined causal and diagnostic reasoning in inference systems," in *Proceedings of the Eighth International Joint Conference on Artificial Intelligence (IJCAI'83)*, A. Bundy, Ed. Karlsruhe, Germany: William Kauffmann, 1983, pp. 190–193.
- [25] M. Henrion, "Some practical issues in constructing belief networks," in *Uncertainty in Artificial Intelligence 5 (UAI'89)*, M. Henrion, R. D. Shachter, L. N. Kanal, and J. F. Lemmer, Eds. Amsterdam, The Netherlands: Elsevier Science Publishers, 1989, pp. 161–173.
- [26] F. J. Díez, "Parameter adjustment in Bayes networks. The generalized noisy OR-gate," in *Proceedings of the Ninth Conference on Uncertainty in Artificial Intelligence (UAI'93)*, D. Heckermann and E. Mamdani, Eds. San Francisco, CA: Morgan Kaufmann, 1993, pp. 99–105.
- [27] F. J. Díez and M. J. Druzdzel, "Canonical probabilistic models for knowledge engineering," UNED, Madrid, Spain, Technical Report CISIAD-06-01, 2006.
- [28] F. J. Díez, "Local conditioning in Bayesian networks," *Artificial Intelligence*, vol. 87, pp. 1–20, 1996.
- [29] —, "Sistema experto bayesiano para ecocardiografía," Ph.D. dissertation, Dpto. Informática y Automática, UNED, Madrid, 1994, in Spanish.
- [30] C. Lacave and F. J. Díez, "Knowledge acquisition in Prostanet, a Bayesian network for diagnosing prostate cancer," *Lecture Notes in Computer Science*, vol. 2774, pp. 1345–1350, 2003.
- [31] C. Lacave, "Explicación en redes bayesianas causales. aplicaciones médicas," Ph.D. dissertation, Dept. Inteligencia Artificial, UNED, Madrid, 2003.
- [32] S. F. Galán and F. J. Díez, "Networks of probabilistic events in discrete time," *International Journal of Approximate Reasoning*, vol. 30, pp. 181–202, 2002.
- [33] N. Alonso-Santander, F. J. Díez, N. F. de Larrea, C. Margalef, and M. Arias, "A probabilistic decision-support system for cataract surgery," in *XXVIII Congress of the ESCRS (European Society of Cataract and Refractive Surgery)*, Paris, France, 2010.
- [34] M. Luque, "Probabilistic graphical models for decision making in medicine," Ph.D. dissertation, UNED, Madrid, 2009.
- [35] M. Luque, F. J. Díez, and C. Disdier, "Optimal sequence of tests for the mediastinal staging of non-small cell lung cancer," *BMC Medical Informatics and Decision Making*, vol. 16, pp. 1–14, 2016.
- [36] D. León, "A probabilistic graphical model for total knee arthroplasty," Master's thesis, Dept. Artificial Intelligence, UNED, Madrid, Spain, 2011.
- [37] M. F. Drummond, M. J. Sculpher, K. Claxton, G. L. Stoddart, and G. Torrance, *Methods for the Economic Evaluation of Health Care Programmes*, cuarta ed. Oxford, UK: Oxford University Press, 2015.
- [38] A. A. Stinnett and J. Mullahy, "Net health benefit: A new framework for the analysis of uncertainty in cost-effectiveness analysis," *Medical Decision Making*, vol. 18, pp. S68–S80, 1998.
- [39] M. Arias and F. J. Díez, "Cost-effectiveness analysis with sequential decisions," UNED, Madrid, Spain, Technical Report CISIAD-11-01, 2011.
- [40] —, "Cost-effectiveness analysis with influence diagrams," *Methods of Information in Medicine*, vol. 54, pp. 353–358, 2015.
- [41] F. J. Díez, M. Luque, and I. Bermejo, "Decision analysis networks," *International Journal of Approximate Reasoning*, vol. 96, pp. 1–17, 2018.
- [42] M. Arias, M. Luque, J. Pérez-Martín, and F. J. Díez, "Cost-effectiveness analysis with decision analysis networks," in *Annual Meeting of the Society for Medical Decision Making*, Pittsburgh, PA, 2017.
- [43] F. J. Díez and M. A. J. van Gerven, "Dynamic LIMIDs," in *Decision Theory Models for Applications in Artificial Intelligence: Concepts and Solutions*, L. E. Sucar, J. Hoey, and E. Morales, Eds. Hershey, PA: IGI Global, 2011, pp. 164–189.
- [44] S. F. Galán, F. Aguado, F. J. Díez, and J. Mira, "NasoNet. Modelling the spread of nasopharyngeal cancer with temporal Bayesian networks," *Artificial Intelligence in Medicine*, vol. 25, pp. 247–254, 2002.
- [45] M. A. J. van Gerven, F. J. Díez, B. G. Taal, and P. J. F. Lucas, "Selecting treatment strategies with dynamic limited-memory influence diagrams," *Artificial Intelligence in Medicine*, vol. 40, pp. 171–186, 2007.
- [46] F. J. Díez, M. Yebra, I. Bermejo, M. A. Palacios-Alonso, M. Arias, M. Luque, and J. Pérez-Martín, "Markov influence diagrams: A graph-

- ical tool for cost-effectiveness analysis,” *Medical Decision Making*, vol. 37, pp. 183–195, 2017.
- [47] I. Bermejo, “New types of probabilistic graphical models: Applications to medicine,” Ph.D. dissertation, Dept. Artificial Intelligence, UNED, Madrid, Spain, 2015.
- [48] J. Pérez-Martín, M. A. Artaso, and F. J. Díez, “Cost-effectiveness of pediatric bilateral cochlear implantation in Spain,” *The Laryngoscope*, 2017. [Online]. Available: <http://dx.doi.org/10.1002/lary.26765>
- [49] Elvira Consortium, “Elvira: An environment for creating and using probabilistic graphical models,” in *Proceedings of the First European Workshop on Probabilistic Graphical Models (PGM’02)*, J. A. Gámez and A. Salmerón, Eds., Cuenca, Spain, 2002, pp. 1–11.
- [50] M. Arias, M. A. Artaso, I. Bermejo, F. J. Díez, M. Luque, and J. Pérez-Martín, “Advanced algorithms for medical decision analysis. Implementation in OpenMarkov,” in *Proceedings of the 16th Conference on Artificial Intelligence in Medicine (AIME 2017)*, Vienna, Austria, 2017.
- [51] I. Bermejo, J. Oliva, F. J. Díez, and M. Arias, “Interactive learning of Bayesian networks with OpenMarkov,” pp. 27–34.
- [52] I. Bermejo, “Probabilistic graphical models for the tuning of systems,” Master’s thesis, Dept. Artificial Intelligence, UNED, Madrid, Spain, 2012.
- [53] I. Bermejo, F. J. Díez, P. Govaerts, and B. Vaerenberg, “A probabilistic graphical model for tuning cochlear implants,” in *Artificial Intelligence in Medicine*, N. Peek, R. Marín, and M. Peleg, Eds. Springer Berlin Heidelberg, 2013, vol. 7885, pp. 150–155.
- [54] F. J. Díez and S. F. Galán, “Efficient computation for the noisy MAX,” *International Journal of Intelligent Systems*, vol. 18, pp. 165–177, 2003.
- [55] M. Luque and F. J. Díez, “Variable elimination for influence diagrams with super-value nodes,” in *Proceedings of the Second European Workshop on Probabilistic Graphical Models (PGM’04)*, P. Lucas, Ed., Leiden, The Netherlands, 2004, pp. 145–152.
- [56] M. Arias and F. J. Díez, “Operating with potentials of discrete variables,” *International Journal of Approximate Reasoning*, vol. 46, pp. 166 – 187, 2007.
- [57] —, “Computation of cost and effectiveness in decision trees with embedded decision nodes,” in *Annual Meeting of the Society for Medical Decision Making*, Pittsburgh, 2007.
- [58] M. Luque, T. D. Nielsen, and F. V. Jensen, “An anytime algorithm for evaluating unconstrained influence diagrams,” in *Proceedings of the Fourth European Workshop on Probabilistic Graphical Models (PGM’08)*, M. Jaeger and T. D. Nielsen, Eds., Hirtshals, Denmark, 2008, pp. 177–184.
- [59] M. Luque and F. J. Díez, “Variable elimination for influence diagrams with super-value nodes,” *International Journal of Approximate Reasoning*, vol. 51, pp. 615–631, 2010.
- [60] M. Luque, T. D. Nielsen, and F. V. Jensen, “Anytime decision-making based on unconstrained influence diagrams,” *International Journal of Intelligent Systems*, vol. 31, pp. 379–398, 2016.
- [61] M. Luque, M. Arias, and F. J. Díez, “Synthesis of strategies in influence diagrams,” in *Proceedings of the Thirty-third Conference on Uncertainty in Artificial Intelligence (UAI’17)*. Corvallis, OR: AUAI Press, 2017, pp. 1–9.
- [62] C. Lacave and F. J. Díez, “A review of explanation methods for Bayesian networks,” *Knowledge Engineering Review*, vol. 17, pp. 107–127, 2002.
- [63] C. Lacave, A. Oniško, and F. J. Díez, “Use of Elvira’s explanation facilities for debugging probabilistic expert systems,” *Knowledge-Based Systems*, vol. 19, pp. 730–738, 2006.
- [64] M. Luque and F. J. Díez, “Decision analysis with influence diagrams using Elvira’s explanation capabilities,” in *Proceedings of the Third European Workshop on Probabilistic Graphical Models (PGM’06)*, M. Studený and J. Vomlel, Eds., Prague, Czech Republic, 2006, pp. 179–186.
- [65] C. Lacave, M. Luque, and F. J. Díez, “Explanation of Bayesian networks and influence diagrams in Elvira,” *IEEE Transactions on Systems, Man and Cybernetics—Part B: Cybernetics*, vol. 37, pp. 952–965, 2007.
- [66] F. Elizalde, L. E. Sucar, M. Luque, F. J. Díez, and A. Reyes, “Policy explanation in factored Markov decision processes,” in *Proceedings of the Fourth European Workshop on Probabilistic Graphical Models (PGM’08)*, M. Jaeger and T. D. Nielsen, Eds., Hirtshals, Denmark, 2008, pp. 97–104.
- [67] F. J. Díez, “Teaching probabilistic medical reasoning with the Elvira software,” in *IMIA Yearbook of Medical Informatics*, R. Haux and C. Kulikowski, Eds. Stuttgart, Germany: Schattauer, 2004, pp. 175–180.
- [68] F. J. Díez, I. París, J. Pérez-Martín, and M. Arias, “Teaching Bayesian networks with OpenMarkov,” in *9th International Conference on Probabilistic Graphical Models*, Prague, Czech Republic, 2018.
- [69] M. Jaeger and T. D. Nielsen, Eds., *Proceedings of the Fourth European Workshop on Probabilistic Graphical Models (PGM’08)*, Hirtshals, Denmark, 2008.



# Research Group on Artificial Intelligence at Universitat Rovira i Virgili (Tarragona)

David Riaño  
Universitat Rovira i Virgili  
Tarragona, Spain  
david.riano@urv.cat

**Abstract**—This paper describes a selection of some of the most representative research lines of the Research Group on Artificial Intelligence (BANZAI) at the Universitat Rovira i Virgili (Tarragona) in the area of Artificial Intelligence in Medicine and the main results achieved. These research interests are: the induction of clinical algorithms, the representation of knowledge to train clinicians, and the study of multimorbidity. Moreover, the paper describes the current and future research interests of the group.

**Keywords**—Research Group on Artificial Intelligence (BANZAI); artificial intelligence in biomedicine; description of research lines and projects.

## I. INTRODUCTION

The Research Group on Artificial Intelligence BANZAI<sup>1</sup>, at the Universitat Rovira i Virgili (Tarragona), was founded in 1998. In the last two decades, the work of the group has been centered in the topics of Intelligent Data Analysis, Knowledge Representation in Health Care, and Clinical Decision Support Systems, in collaboration with several hospitals in Barcelona, Tarragona, and Reus.

In 2000 the group collaborated with the Hospital Universitari Joan XXIII (Tarragona) in the project *COSYS: Sistema de Informació Hospitalaria de Ayuda a la Adaptació de Pesos Relatius a los GRD*. In this project, a tool was developed to classify patients in order to simplify the comparison between the real costs of inpatients and the relative weights of the Diagnostic Related Groups (DRG) [1][2]. In 2003, they worked with the Palliative Care Unit at the Hospital de la Santa Creu i Sant Pau (Barcelona) in the project *Palliasys: Use of new ICT to facilitate the treatment of palliative patients* in order to implement a eHealth system to assist patients requiring palliative care at home, but also in the analysis of retrospective data about patients attended in the unit in order to find out medical protocols of efficient medical practices [3]-[10]. In 2006, they coordinated the project *Hygia* with the Hospital Clínic de Barcelona, the University of Santiago de Compostela and Universitat Jaume I. The contribution of BANZAI in the project was the analysis of

retrospective data to construct treatment models for chronic patients [11]-[13]. Later on, in 2006, they coordinated the project *K4CARE: Knowledge-Based Home-Care eServices for an Ageing Europe* that counted on several hospitals in Europe, apart of some technological partners [14]. The project combined healthcare and ICT experiences of several western and eastern EU countries to create, implement, and validate a knowledge-based health-care model for the professional assistance to senior patients at home [15]-[17].

In the last eleven years, this research group has organized international workshops every year in the field of health-care knowledge representation. Since 2009, this workshop is called *K4CARE: Knowledge Representation for Health-Care* and, in 2018, it was the tenth edition. They are also editors of the Springer LNAI book series on "Knowledge Representation for Health Care" (eight books published until 2018) containing the extended versions of a selection of the best papers in those workshops.

The rest of the paper is organized in two sections: in the first one, three research lines showing the current interests of the BANZAI group are described. In the second one, a short discussion of the future interests is provided with conclusions.

## II. RESEARCH LINES AND RESULTS

### A. Induction of Clinical Algorithms

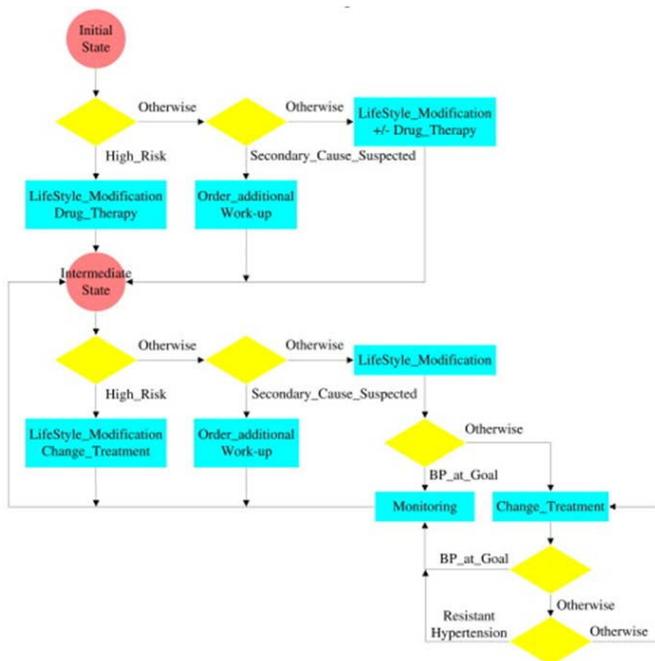
Chronic patients are characterized by requiring continuous follow-up for long periods of time, years, or even for lifetime. This timeline process is described by the clinical concept of Episode of Care (EOC) which can be defined as the services provided to a patient within a specific problem during a certain period of time. The EOC are based on the idea of clinical encounter in which the health-care professional (physician or nurse) observes the clinical condition of the patient (state), decides which issues require attention, and suggest clinical actions to address these issues. An EOC is then a sequence of encounters, and each encounter simplified as a vector (S, D, A) where S stands for the state of the patient, D are the decided issues requiring attention, and A the clinical actions performed or started in that particular encounter to address D.

<sup>1</sup> <http://banzai-deim.urv.cat>

Primary care services register all this information in their databases or in the patients EHRs.

In modern medicine, clinical quality is related to the sort of evidences registered in the clinical practice guidelines. These are documents gathering all the clinical knowledge available for specific diseases. Therefore, the quality of medical practice uses to be related to the level of adherence of clinicians and patients to the evidences in these guidelines. Unfortunately, it is not easy to check adherence. However, in order to promote adherence, clinical processes can be simplified and represented as intuitive clinical algorithms such as the one in Fig. 1, and finally incorporated to the guidelines.

FIGURE I. CLINICAL ALGORITHM



In this context, BANZAI and SAGESSA<sup>2</sup> worked together to automate the process of clinical algorithm extraction from EOC databases. Clustering technologies were developed to isolate relevant states and treatment blocks (circles and squares in Fig. 1) from EOC data, and combined algorithms to induce decision trees were proposed to intertwine states and actions with decisions (diamonds in Fig. 1) [18]. These algorithms were used to compare clinical procedures across institutions and in contrast with clinical algorithms recommended in different clinical practice guidelines [19].

**B. Knowledge Representation for Clinical Training**

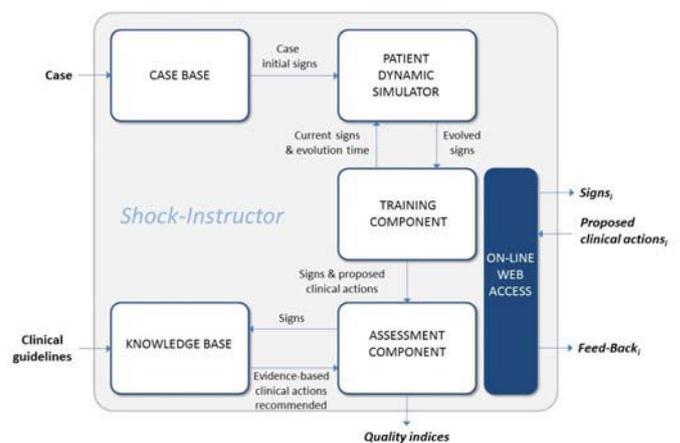
Clinical practice is a complex task in which several decision problems combine in sophisticated models, as the one proposed by BANZAI [20]: the MPM. Three of the main decision problems in these models are diagnosis, treatment, and prognosis, though these can comprise multiple subtypes.

<sup>2</sup> SAGESSA is an entity that manages all the clinical services in the south of Tarragona, including four hospitals, five primary care centers, and four rehabilitation centers.

Representing medical knowledge with AI structures to support decisions for these three decision problems starts with the selection of appropriate representation models. One of these models are decision tables [21][22]. Interestingly, once constructed and validated, these knowledge structures are not only useful to support decision making, but also to train novel clinicians to make the right decisions.

In collaboration with the Emergency Department of the Clinical Hospital in Barcelona (HCB), the BANZAI group worked to formalize the knowledge available in multiple clinical practice guidelines as grouping decision tables. These tables were wrapped by a web-based system to train residents of the HCB and to analyze the benefits of this sort of computer-based learning in medicine. The training system, whose functional architecture is shown in Fig. 2, was used to improve residents skills in (1) applying differential diagnosis to secondary causes of hypertension [23], (2) providing the right treatment of emergency shock in ERs and ICUs [24], and (3) simulating emergency shock to prognosticate patient evolutions [25].

FIGURE II. SHOCK-INSTRUCTOR TRAINING TOOL ARCHITECTURE



These studies concluded that the use of knowledge-based e-learning computer tools can significantly improve the learning curve, the adherence, and the clinical results of novel residents beyond traditional formative programs in schools of medicine, and hospitals.

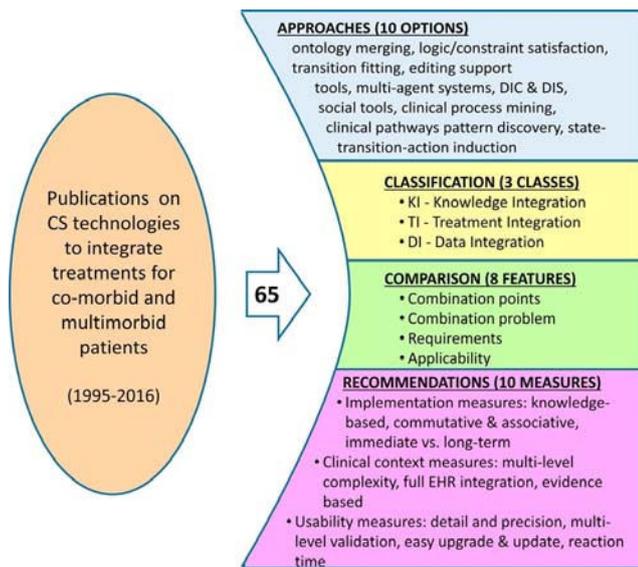
**C. Dealing with Multimorbidity**

Multimorbidity is the simultaneous observation of more than one disease in the same patient. This is a common clinical condition of elderly patients, more inclined to suffer several chronic ailments. The management of multimorbid patients is challenging because of many reasons such as some issues related to polypharmacy or the lack of evidence about multimorbid cases. On the contrary, the number of multimorbid cases increases year after year, and consequently the amount of clinical data generated about the treatment and evolutions of these cases is large and growing rapidly. We performed a review of CS technologies applied to the management of multimorbid patients [26] whose results are summarized in Fig. 3. Three alternative technologies were identified: knowledge integration, treatment integration, and data integration.



FIGURE III.

## COMPARISON OF CS TECHNOLOGIES FOR MULTIMORBIDITY



*Knowledge integration* is about the combination of single-disease knowledge structures (and additional clinical knowledge) to generate multimorbid knowledge structures. Several works exist following this approach, among which the BANZAI group proposed a technology that adapts general Formal Intervention Plans (similar to clinical algorithms, seen in Fig. 1) into Individual Intervention Plans according to the constraints of an ontology containing complementary clinical knowledge and the EHR of the patient. Individual Intervention Plans of different diseases for the same patient can be combined into a Unified Intervention Plan to define holistic personalized treatment for that multimorbid patient.

*Treatment integration* is seen as the combination of clinical lists of actions (including prescriptions and procedures) by solving cross interactions between actions for different diseases. In [27], a rule-based system to combine treatments of hypertension and/or diabetes mellitus and/or heart failure was proposed and tested on twenty multimorbid patients. In a later work [28], we also proposed a semi-automatic methodology to combine treatments that are expressed under a "global" structure of patient management in primary, secondary, and tertiary care.

*Data integration* is based on the idea of extracting knowledge about the treatment of multimorbid patients, from the intelligent analysis (machine learning) of databases about the management of this sort of patients. Our approach, different from other process mining approaches, is a machine learning process in which EOC about multimorbid patients are transformed into SDA clinical algorithms (Fig. 1) [12][29].

### III. FUTURE LINES AND CONCLUSIONS

Today, some of the above described research lines of the Research Group on Artificial Intelligence (BANZAI) have converged in some interesting and challenging issues that will determine the course of our future research. Here, we describe four of them, broadly.

*The analysis of ICU data:* Intensive Care Units are singular services in the sense that they produce a huge amount of data per patient, the related costs are high, the patients are very sensitive and they may require rapid interventions by coordinated (sometimes multidisciplinary) expert teams. We are in close collaboration with the ICU of the Hospital Universitari Joan XXIII (Tarragona) in order to define a big data for scientific exploitation, similar to the USA database MIMIC III. In this collaboration, our main contribution is the analysis of these data with data mining technologies and the construction of descriptive and predictive models to solve important medical questions such as the length of stay, the parameters affecting the length of stay, advanced detection of patient's complications and changes of state, the accurate use of antibiotics and the pharmacological consumption in general, or the adherence to ICU guidelines.

*The analysis of cancer data:* We are concluding a preliminary longitudinal study on breast cancer data coming from the SEER database. We are also participating in the *P-BreasTreat* project, one of whose objectives is the combination of visual data extracted from the analysis of images, with clinical data taken from the patient EHR to classify cancer's typology. This work is in conjunction with the Oncology Service of the Hospital Sant Joan (Reus).

*Multimorbidity:* Although, we achieved considerable results in this topic in the past, there are still some open questions that we would like to address in our close future. Just to mention some, we are interested in determining whether there are significant differences in the interactions detected by different publicly available drug interaction checkers, or the automatic construction of diagrams to evidence the differences between the treatments of one disease for monomorbid patients, in comparison with the treatment of this same disease in multimorbid patients. Gaining insight in multimorbidity management will influence the next research line for the future.

*Data synthetization:* Data about clinical processes and patients are highly sensitive and subject to strict legal restrictions. Anonymization is a way to exempt the data analyzer from legal issues, but it does not solve the case of disambiguation by crossing databases. An alternative approach is to construct mechanisms for data synthetization. In one preliminary study [30] we identified three alternative methods for clinical data synthetization: statistical, knowledge representation, and simulation. The *statistical method* uses the available data about real patients to construct a statistical model of the clinical parameters, and then a generator uses this model to synthesize treatments about fictitious patients. The *knowledge representation method* integrates the available knowledge (in clinical guidelines, health-care ontologies, electronic books, web sites, etc.) into a knowledge base and then it synthesizes fake treatments that are consistent with the knowledge base. Finally, the *simulation method* depends on the availability of a patient (or signs) simulator that emulates the evolution of that patient or signs when a treatment is carried out. Combining the simulator with a treatment recommender system, and making these elements to loop, a database can be synthesized containing specific fictitious treatments.

In conclusion, the Research Group in Artificial Intelligence at the Universitat Rovira i Virgili (Tarragona) has been working in the area of medical informatics since 1998 with two main technological focuses: intelligent data analysis and knowledge representation. We have a wide trajectory collaborating with multiple hospitals and health-care centers in general. Our current and future interests are in the analysis of ICU and cancer data, and the synthetization of EHR data for multimorbid conditions.

#### ACKNOWLEDGMENT

This paper has been possible thanks to the RETOS P-BreasTreat project (DPI2016-77415-R) of the Spanish *Ministerio de Economía y Competitividad*.

We want to thank all the physicians that have collaborated with our group along these years: Dr. Xavier Allué, Dr. Montserrat Olona, Dr. Antonio Pascual, Dr. Silvestre Martín, Dr. Albert Alonso, Dr. Patrizia Meccoci, Dr. María Bodí, Dr. Alejandro Rodríguez, and primarily to Dr. Antoni Collado, Dr. José Ramón Alonso, Dr. Fabio Campana, and Dr. Roberta Annicchiarico. We are also thankful to all the current and past CS members of the group: Dr. John A Bohada, Dr. Joan Albert López-Vallverdú, Dr. Aida Kamisalik, Dr. Francis Real, Ms. Susana Prado, Mr. Mohammed Sayed, Mr. Wilfrido Ortega, and undergraduate and master students.

#### REFERENCES

- [1] Riaño D, Prado S, "The analysis of hospital episodes," Second Int. Symposium on Medical Data Analysis (ISMDA 2001), In: Medical Data Analysis, LNCS 2199, Jose Crespo, Victor Maojo and Fernando Martin (Eds.), Madrid, Spain. 2001.
- [2] Riaño D, Prado S, "The Study of Medical Costs with Intelligent Information Systems," 15th IEEE Symposium on Computer Based Medical Systems (CBMS 2002), Maribor, Slovenia, 2002.
- [3] Riaño D, Prado S, Pascual A, Martín S, "A Multiagent System Model to Support Palliative Care Units," 15th IEEE Symposium on Computer Based Medical Systems (CBMS 2002), Maribor, Slovenia, 2002.
- [4] A. Pascual, Riaño D, Prado S, López C, Martín S, "Un Modelo de Sistema Multiagente en un Programa de Cuidados Paliativos," Congreso Nacional de Paliativos, Granada, 2002.
- [5] Moreno A., Valls A., Riaño D, "Improving Palliative Care with Agent Technology," Workshop ECAI, 2004.
- [6] Riaño D, Moreno A, Valls A, "Palliasys: Agent Based Palliative Care," IEEE 4th Conf. on Intelligent Systems Design and Applications (ISDA'04), ISBN 963 7154 29 9, Budapest, Hungría, 2004.
- [7] Moreno A, Riaño D, Pascual A, Valls A, Mallafre X, "Sistema Telemático para la gestión de Unidades de Curas Paliativas," Informed 2004, Barcelona, 2004.
- [8] Valls A, Moreno A, Riaño D, Pascual A, "Modelo de e-Asistencia Basado en las Tecnologías de SMAs y Análisis Inteligente de Datos," Informed 2004, Barcelona, 2004.
- [9] Moreno A, Riaño D, Valls A, "Agent-based alarm management in a Palliative Care Unit," 3rd Workshop on Agents Applied in Health Care, IJCAI 2005, Edinburgh, 2005.
- [10] Moreno A, Valls A, Riaño D, "PalliaSys: agent-based proactive monitoring of palliative patients," 4th Int Workshop on Practical Applications of Agents and Multi-Agent Systems, IWPAAMS-05, p. 101-110, León, 2005.
- [11] Real F, Riaño D, (2008) Automatic Combination of Formal Intervention Plans Using SDA\* Representation Model. In: Riaño D. (eds) Knowledge Management for Health Care Procedures. K4CARE 2007. Lecture Notes in Computer Science, vol 4924. Springer, Berlin.
- [12] Riaño D, López-Vallverdú JA, Tu S, (2008) Mining Hospital Data to Learn SDA\* Clinical Algorithms. In: Riaño D. (eds) Knowledge Management for Health Care Procedures. K4CARE 2007. Lecture Notes in Computer Science, vol 4924. Springer.
- [13] Lozano E, Marcos M, Martínez-Salvador B, Alonso A, Alonso JR, (2010) Experiences in the Development of Electronic Care Plans for the Management of Comorbidities. In: Riaño D., ten Teije A., Miksch S., Peleg M. (eds) Knowledge Representation for Health-Care. Data, Processes and Guidelines. KR4HC 2009. LNCS 5943. Springer.
- [14] Riaño D, Campana F, Annicchiarico R, Ercolani S, Federici A, Mecocci P, "K4CARE: a new intelligent system for home care," 6th Int. Conf. of the International Society for Gerontechnology, Pisa, Italy, 2008. Journal of the Int. Society for Gerontechnology 7(2): 195, 2008.
- [15] Spiru L, Turcu I, Ioancio I, Nuta C, Ghita C, Martin M, Annicchiarico R, Cortés U, Riaño D, "E-Health and Assistive Technology (AT) as suitable answers to global aging," Alzheimer's and Dementia: Journal of the Alzheimer's Association 5(4) supplement: 241, 2009.
- [16] Riaño D, Real F, Campana F, Ercolani S, Annicchiarico R, "An Ontology for the Care of the Elder at Home," AIME'09, Jul 18-22, Verona, Italy, 2009.
- [17] Riaño D, Real F, López-Vallverdú JA, Campana F, Ercolani S, Mecocci P, Annicchiarico R, Caltagirone C, "An ontology-based personalization of health-care knowledge to support clinical decisions for chronically ill patients," Int. Journal of Biomedical Informatics. 45(3): 429-446, 2012. Also published in the JBI Virtual Issue on Computer-interpretible Clinical Guidelines (Ed. Mor Peleg), 2013.
- [18] López-Vallverdú JA, Riaño D, Bohada JA, "Improving medical decision trees by combining relevant health-care criteria," Expert Systems with Applications, 39(14): 11782-11791, 2012.
- [19] Bohada JA, Riaño D, Lopez-Vallverdú JA, "Automatic Generation of Clinical Algorithms within the SDA Model," Expert Systems with Applications, 39(12): 10709-10721, 2012.
- [20] Riaño D, Bohada JA, Collado A, López-Vallverdú JA, "MPM: A Knowledge-Based Model of Medical Practice," Int. Journal of Biomedical Informatics, 46(3): 379-387, 2013.
- [21] Riaño D, "A Systematic Analysis of Medical Decisions. How to Store Knowledge and Experience in Decision Tables," LNAI 6924. pp 23-36, 2012.
- [22] Real F, "Use of Decision Tables to Model Assistance Knowledge to Train Medical Residents," PhD Thesis Dissertation, URV, 2016.
- [23] Real F, Riaño D, Alonso JR, "Training Residents in the Application of Clinical Guidelines for Differential Diagnosis of the most Frequent Causes of Arterial Hypertension with Decision Tables," 6th Int. Wshp. on Knowledge Representation for Health-Care, KR4HC 2014, Vienna, Austria.
- [24] Riaño D, Real F, Alonso JR, "Improving resident's skills in the management of circulatory shock with a knowledge-based e-learning tool," Int J Med Inform. 2018 113:49-55.
- [25] Real F, Riaño D, Alonso JR, "A Patient Simulation Model Based on Decision Tables for Emergency Shocks," 7th Int. Wshp. on Knowledge Representation for Health-Care, KR4HC 2015, Pavia, Italy.
- [26] Riaño D, Ortega W, "Computer technologies to integrate medical treatments to manage multimorbidity," JBI 75 (2017).
- [27] López-Vallverdú JA, Riaño D, Collado A, "Rule-Based Combination of Comorbid Treatments for Chronic Diseases Applied to Hypertension, Diabetes Mellitus, and Heart Failure," LNAI 7738, 30-41, 2013.
- [28] Riaño D, Collado A. "Model-Based Combination of Treatments for the Management of Chronic Comorbid Patients," 14th Int. Conf. on Artificial Intelligence in Medicine, Murcia, Spain. In: Artificial Intelligence in Medicine. Springer LNAI 7885, 11-16.
- [29] López-Vallverdú JA, Knowledge-Based Incremental Induction of Clinical Algorithms, PhD Thesis Dissertation, 2012.
- [30] Riaño D., Fernández-Pérez A, "Simulation-Based Episodes of Care Data Synthetization for Chronic Disease Patients," Knowledge Representation for Health Care. ProHealth 2016, KR4HC 2016. LNCS 10096. Springer.



# Research Topics in Computer-Interpretable Guidelines

Mar Marcos, Begoña Martínez-Salvador  
 Dept. of Computer Engineering and Science  
 Universitat Jaume I  
 Castellón, Spain  
 {mar.marcos, begona.martinez}@uji.es

Cristina Campos, Reyes Grangel  
 Dept. of Computer Languages and Systems  
 Universitat Jaume I  
 Castellón, Spain  
 {camposc, grangel}@uji.es

**Abstract**—This paper describes some lines of research of the Knowledge Engineering group at Universitat Jaume I, which investigates the construction of knowledge-based systems with an emphasis on practical applications. In particular, the paper presents a selection of research lines in the context of Computer-Interpretable Guidelines, a topic in which the group has specialised over the last years.

**Index Terms**—Knowledge Engineering, Clinical Decision-Support Systems, Clinical Practice Guidelines, Computer-Interpretable Guidelines

## I. INTRODUCTION: KNOWLEDGE ENGINEERING GROUP AT UNIVERSITAT JAUME I

This paper describes the main research activities of the Knowledge Engineering (KE) group at Universitat Jaume I. The group investigates the construction of knowledge-based systems, with a special emphasis on practical applications in the field of Medicine. The KE group was founded in 2003 as a result of the consolidation of research activities initiated in collaboration with groups of other universities and research centers at European level, in the framework of the EU projects Protocure I and II [1], [2]. Among the medical applications, the KE group has been working for a long time on decision-support systems developed from Clinical Practice Guidelines. Another topic the KE group has paid attention to is the quality assurance of knowledge-based systems in general, and of clinical decision-support systems in particular. The group is also interested in knowledge representation in different fields (e.g. Medicine, Enterprise) and using different approaches (e.g. rule-based, ontologies, business process models).

## II. CONTEXT: COMPUTER-INTERPRETABLE GUIDELINES

In the field of Medicine, the KE group has specialised for some time now in Clinical Practice Guidelines (CPGs) and their counterpart in electronic format, the so-called Computer-Interpretable Guidelines (CIGs). According to the most recent definition, CPGs are “statements that include recommendations intended to optimize patient care that are informed by a systematic review of evidence and an assessment of the benefits and harms of alternative care options” [3]. Research

has demonstrated that CPGs have the potential to improve the quality and outcomes of healthcare. To achieve these benefits, CPG recommendations should be made available to clinicians where and when they are needed [4]. Although this can be done using CPGs in text form, there is consensus that the most effective way is by converting them to a computer-interpretable format [5]. Thus, CIGs can be defined as electronic versions of CPG documents to be executed as part of decision-support systems.

CPGs are developed using methods that incorporate principles of *Evidence-Based Medicine* and consensus recommendations made by panels of experts, in the context of a specific clinical condition. As for their appearance and structure, CPGs are more or less lengthy documents describing neatly and in detail the recommended diagnostic and therapeutic interventions. CPGs often include tables summarising the key recommendations as well as flowcharts structuring the interventions, for ease of reference. The information provided in summary tables usually includes the class of recommendation, the level of evidence and the supporting literature reference(s). As an illustration of CPG documents, the reader is referred to e.g. the 2012 ESC guidelines for the diagnosis and treatment of acute and chronic heart failure [6].

CIGs have been an active topic in the Artificial Intelligence (AI) in Medicine field for over 20 years. The emergence of CIGs was motivated by the interest in making CPG recommendations available to clinicians in an easier and immediate way, as opposed to CPG documents. In a review work, Peleg identifies a total of 8 research themes in the CIG area [4]:

- 1) Representation languages
- 2) Acquisition and specification methodologies
- 3) Integration with Electronic Health Record (EHR) systems and with workflow systems
- 4) Verification & validation
- 5) Execution engines and other CIG-related tools
- 6) Exception and error handling
- 7) Maintenance
- 8) Sharing and reuse

The KE group has been involved in projects related to several of the above themes, concretely: verification & validation, acquisition and specification, sharing and reuse, and

This work has been partially funded by the Spanish Ministry of Economy, Industry and Competitiveness and the European Regional Development Fund (ERDF) Programme through grant TIN2014-53749-C2-1-R.

interoperability with EHR systems. Besides, the group has wide experience in CIG modelling using the PROforma representation language [7]. The following sections briefly describe a selection of the lines of research in which the group has been recently working, and the ongoing projects.

### III. RESEARCH LINES

#### A. Interoperability between CIG and EHR systems

1) *Biomedical problem and its impact*: To be effective, CIG systems must be integrated within clinical information systems. The interoperability with the EHR is the main obstacle hindering this integration. On the side of the EHR the main problem is the heterogeneity of clinical data sources, which may differ in used data models, schemas, naming conventions and level of detail. On the side of CIGs the issue is that used data is often at a level of abstraction much higher than that of the clinical data in the EHR (the so-called “impedance mismatch”).

The potential impact of interoperability solutions providing access to EHR data from CIG systems can be huge for healthcare quality. Additionally, applications related to the secondary use of EHR data, e.g. in clinical research, can benefit from the same kind of solutions.

2) *Research team(s)*: The KE group first worked in this line of research in collaboration with the Instituto de Aplicaciones de las Tecnologías de la Información y de las Comunicaciones Avanzadas (ITACA), Universitat Politècnica de València, and with clinical collaborators from the Oncological Institute at Hospital Provincial de Castellón [8], [9]. In a different case study, the same teams worked with the Departamento de Informática y Sistemas, Universidad de Murcia, and with clinical experts from the Fundación para la Formación e Investigación Sanitaria of Murcia [10].

3) *Approach*: The approach seeks to solve the interoperability problems between CIG and EHR systems using generic EHR architectures, concretely openEHR archetypes (standardised information models for specific clinical concepts). It can be summarised in the following steps (see also Figure 1):

- An appropriate integration archetype (or archetypes) must be designed for the data/concepts used in the CIG
- It must be ensured that the CIG includes references to this archetype in the parts where interactions with the EHR are required
- It must be ensured that the connection with the EHR through the integration archetype is feasible, which implies the definition of a series of mappings between the elements of the archetype and the data elements of the EHR

#### B. Utilisation of workflow patterns in the acquisition of CIG procedural knowledge

1) *Biomedical problem and its impact*: CPGs are difficult to understand and formalise, because they are aimed at clinicians with specialised background knowledge. Moreover, CPGs are often composed of sets of procedures with logical gaps or

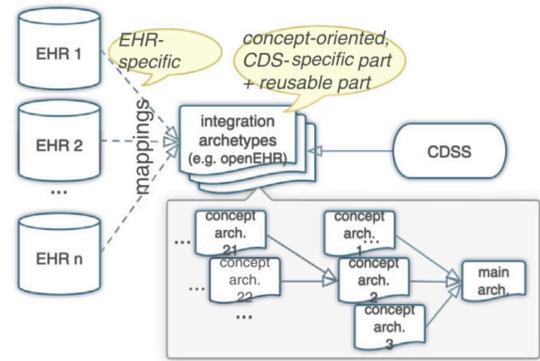


Fig. 1. Linking a CIG system to different EHR systems (extracted from Fig. 4 by Marcos *et al.* [9]).

contradictions. On the other hand, CIG representation languages provide a wide range of modelling constructs tailored to the different knowledge types found in CPGs (procedures, decision criteria, abstract concepts, etc.). This makes CIG languages poorly accessible and understandable for clinicians, in general. As result of these factors, CIG knowledge acquisition is usually carried out by joint teams made up of clinical and IT experts. This line of work seeks to facilitate the initial phases of knowledge acquisition of CIGs, by providing procedural patterns in a notation that can be further refined into different target CIG languages.

The use of patterns can reduce modelling time and enable stakeholders to communicate more precisely and in a less ambiguous way, with consequent benefits. Besides, a faster modelling can serve to translate CPG recommendations almost immediately to a CIG system that can be used at the point of care, which would have a positive impact on healthcare quality.

2) *Research team(s)*: This work was carried out jointly by the KE group and the Institute of Software Technology & Interactive Systems, Vienna University of Technology [11].

3) *Approach*: The overall idea was to provide a series of procedural patterns in a notation (1) that is intuitive for clinicians and (2) that can be easily refined into different CIG languages. For the patterns, the so-called workflow control patterns, which are frequent task (and control) structures identified in the fields of workflow systems and business process modelling, were used. As implementation-independent notation for the description of the patterns, the BPMN notation was chosen. The most important result was the analysis of the adequacy of workflow control patterns for the representation of CPG procedural knowledge, and the identification of additional patterns, using a sample of CPG texts [11].

#### C. Transformation algorithms for the acquisition of CIG procedural knowledge

1) *Biomedical problem and its impact*: With a similar motivation (and potential impact) of that of the previous work, this line of research seeks to provide support for the refinement of CIG procedures from an initial specification in BPMN to



an implementation in a CIG representation language, possibly different ones, in a (semi)automatic way (see Figure 2).

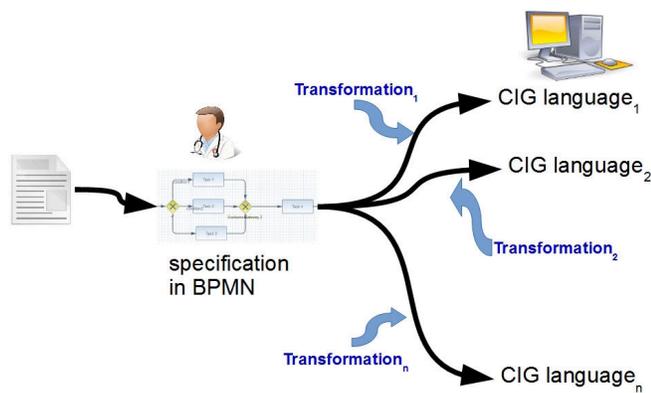


Fig. 2. Supporting the refinement of clinical process models into CIG models.

2) *Research team(s)*: This work was carried out by the KE group, in collaboration with the Research Group on Artificial Intelligence, Universitat Rovira i Virgili, in some of its parts [12], [13].

3) *Approach*: As mentioned above, BPMN was used as notation for the specification of CIGs. As for the target CIG representation languages, PROforma [13] and SDA [12] were considered. In both cases the transformation algorithm follows a structure identification strategy, which focuses on certain structures of interest in the target language and identifies the source BPMN structures that correspond to the former ones. The algorithm works with source BPMN models/graphs which may contain sub-graphs, which typically occur in the case of CPGs.

#### IV. ONGOING WORK

Current research activities of the KE group are mainly dedicated to the CLIN-IK-LINKS project, “*Clinical Information and Knowledge Models for Linking Electronic Health Record and Clinical Decision Support Systems*”, funded by the Spanish Ministry of Economy and Competitiveness (reference TIN2014-53749-C2-1-R). The aim of this project is to enable interoperability of EHR and CDS systems in an effective and efficient way (research theme #3 in Peleg’s review [4]). For this purpose, we investigate the combination and joint exploitation of the most advanced technologies for information, domain, and inference models. The project is carried out in collaboration with the Departamento de Informática y Sistemas, Universidad de Murcia, and with the company VeraTech for Health SL. Within this project, we are developing a platform for the configuration and execution of web services for clinical data transformation and reasoning processes [14]. The project also includes tasks addressing the execution of interoperable CIGs (combination of research themes #3 and #5 in Peleg’s list).

Other ongoing research activities are related to CIG knowledge acquisition, and to CIG verification & validation (research themes #2 and #4 in Peleg’s list). As a continuation

of the work described in section III-C1, we are currently working on model transformation methods for CIGs using Model-Driven Engineering (MDE) tools. In connection with the verification & validation of CIGs, we are working on structural metrics that can be used to assess the quality of CIG model design (e.g. to detect certain maintainability issues), in line with what is done in the Software Engineering field.

#### V. CONCLUSIONS AND OUTLOOK

The field of Medicine in general and the CPG/CIG area in particular present challenges and opportunities requiring new methods and techniques that can be addressed from an AI perspective. To take one example, the acquisition of knowledge of CPGs and the development of CIGs is usually tackled once the final CPG texts have been published. In this context, we are interested in the design of environments for knowledge management of CPGs, following the directives of medical organisations and taking into account the requirements for the further development of different types of support tools, CIGs or others.

#### REFERENCES

- [1] A. ten Teije, M. Marcos, M. Balsler, J. Van Croonenborg, C. Duelli, F. van Harmelen, P. Lucas, S. Miksch, W. Reif, K. Rosenbrand, and A. Seyfang. Improving medical protocols by formal methods. *Artif Intell Med*, 36(3):193–209, 2006.
- [2] M. Balsler, O. Coltell, J. Van Croonenborg, C. Duelli, F. Van Harmelen, A. Jovell, P. Lucas, M. Marcos, S. Miksch, W. Reif, K. Rosenbrand, A. Seyfang, and A. Ten Teije. Protocore: Supporting the development of medical protocols through formal methods. volume 101, pages 103–107, 2004.
- [3] Institute of Medicine. *Clinical Practice Guidelines We Can Trust*. The National Academies Press, Washington, DC, 2011.
- [4] M Peleg. Computer-interpretable clinical guidelines: A methodological review. *J Biomed Inform*, 46(4):744–763, 2013.
- [5] F A Sonnenberg and C G Hagerty. Computer-interpretable clinical practice guidelines. where are we and where are we going? *Yearb Med Inform*, pages 145–158, 2006.
- [6] The Task Force for the Diagnosis and Treatment of Acute and Chronic Heart Failure 2012 of the European Society of Cardiology. ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure 2012. *Eur Heart J*, 33(14):1787–1847, 2012.
- [7] J Fox, N Johns, and A Rahmzadeh. Disseminating medical knowledge: The PROforma approach. *Artif Intell Med*, 14(1-2):157–181, 1998.
- [8] M Marcos, J A Maldonado, B Martínez-Salvador, D Moner, D Boscá, and M Robles. An archetype-based solution for the interoperability of computerised guidelines and electronic health records. In *Proc. of the 13th Conference on Artificial Intelligence in Medicine, AIME 2011.*, pages 276–285, 2011.
- [9] M Marcos, J A Maldonado, B Martínez-Salvador, D Boscá, and M Robles. Interoperability of clinical decision-support systems and electronic health records using archetypes: A case study in clinical trial eligibility. *J Biomed Inform*, 46(4):676–689, 2013.
- [10] J T Fernández-Breis, J A Maldonado, M Marcos, M C Legaz-García, D Moner, J Torres-Sospedra, A Esteban-Gil, B Martínez-Salvador, and M Robles. Leveraging electronic healthcare record standards and semantic web technologies for the identification of patient cohorts. *J Am Med Inform Assoc*, 20(e2):e288–e296, 2013.
- [11] K Kaiser and M Marcos. Leveraging workflow control patterns in the domain of clinical practice guidelines. *BMC Med Inform Decis Mak*, 16(20), 2016.
- [12] B Martínez-Salvador, M Marcos, and D Riaño. An Algorithm for Guideline Transformation: From BPMN to SDA. *Procedia Computer Science*, 63:244 – 251, 2015. 5th International Conference on Current and Future Trends of Information and Communication Technologies in Healthcare (ICTH-2015).



- [13] B Martínez-Salvador and M Marcos. Supporting the Refinement of Clinical Process Models to Computer-Interpretable Guideline Models. *Bus Inform Syst Eng+*, 58(5):355–366, Oct 2016.
- [14] J A Maldonado, M Marcos, J T Fernández-Breis, E Parceró, D Boscá, M C Legaz-García, B Martínez-Salvador, and M Robles. A platform for exploration into chaining of web services for clinical data transformation and reasoning. *AMIA Annu Symp Proc*, 2016:854863, 2016.



# Investigación en Inteligencia Artificial en Medicina del grupo AIKE de la Universidad de Murcia

Manuel Campos, Bernardo Cánovas-Segura, María A. Cardenas, Félix Gomez de León, Fernando Jimenez  
Jose M. Juarez, Roque Marin, Antonio Morales, Jose T. Palma

*Facultad de Informática*

*Universidad de Murcia*

{manuelcampos|mariancv|bernardocs|gdleon|  
fernand|jmjuarez|roquemm|morales|jtpalma}@um.es

Francisco Palacios

*Unidad de Cuidados Intensivos*

*Hospital Universitario de Getafe*

Madrid, Spain

franciscodepaula@gmail.com

**Resumen**—En este trabajo presentamos la actividad del grupo de investigación en Inteligencia Artificial e Ingeniería del Conocimiento (AIKE) en el ámbito de la Inteligencia Artificial en Medicina. En concreto resumimos sus principales líneas de investigación: razonamiento temporal, razonamiento basado en casos, lógica espacio-temporal, representación del conocimiento y computación evolutiva. Finalmente describimos los proyectos realizados más recientes en el campo de la salud.

**Index Terms**—Inteligencia Artificial en Medicina; Razonamiento Temporal; Lógica Temporal; Representación del Conocimiento; Computación Evolutiva.

## I. INTRODUCCIÓN

El grupo de Inteligencia Artificial e Ingeniería de Conocimiento (AIKE)<sup>1</sup> de la Universidad de Murcia, fundado en 1.993 por Roque Marín, es un grupo multidisciplinar actualmente compuesto por 25 miembros del ámbito de la informática, la ingeniería, física y medicina. Su actividad investigadora se centra en la aplicación de la Inteligencia Artificial (IA) principalmente en el dominio de la salud y también en el diagnóstico y la monitorización industrial.

En este trabajo se centra en la contribución del grupo AIKE en el ámbito de la Inteligencia Artificial en Medicina. Este documento se describen:

- Las líneas de investigación en Inteligencia Artificial y sus principales contribuciones (Sec. II).
- Los proyectos desarrollados más recientes en el ámbito de la Inteligencia Artificial aplicada a la salud (Sec. III).
- Las lecciones aprendidas y los retos a abordar en trabajos futuros (Sec. IV).

## II. LÍNEAS DE INVESTIGACIÓN

A continuación describimos los principales ejes de investigación y resultados del grupo AIKE a lo largo de los años,

<sup>1</sup><http://www.um.es/aike/>

incluyendo los referentes a los proyectos DAISY y WASPSS que se describirán en la Sec. III.

### II-A. Razonamiento Temporal Borroso

La línea más antigua del grupo AIKE se centra en métodos de representación y resolución de problemas de restricciones donde el tiempo juega un papel básico.

Uno de los principales resultados en esta línea son las Redes de Restricciones Temporales Borrosas (*FTCN*) [1], [2]. Una *FTCN* está formada por un conjunto de variables temporales y un conjunto finito de restricciones temporales binarias definidas sobre las variables temporales. Una *FTCN* puede representarse mediante un grafo dirigido, donde los nodos representan las variables temporales y los arcos representan las restricciones binarias temporales. A partir de aquí se han desarrollado técnicas de inferencia para obtener relaciones antes desconocidas y propagar restricciones obteniendo la red mínima. Estos resultados teóricos han sido implementados de diferente forma para dar soluciones en distintos contextos del ámbito médico.

También destacamos el software *FuzzyTIME*, un razonador temporal de propósito general que permite trabajar con restricciones temporales borrosos entre puntos e intervalos temporales. *FuzzyTIME* proporciona herramientas para el mantenimiento y la consulta de información temporal de las redes *FTCN*, utilizando sentencias en lenguaje de alto nivel. Por ejemplo, en [3] se demuestra su utilidad para dar soluciones en el escenario de la Gripe Aviar.

La necesidad de proporcionar descripciones de alto nivel de la evolución de datos es esencial en el dominio médico, obteniendo información más fácil de comparar y tamaño más reducido. Así, se han desarrollado técnicas de abstracción temporal basadas en *FTCN* [4] [5].

## II-B. Lógicas Espaciales y Temporales

Una segunda línea de investigación básica del grupo AIKE es el desarrollo de modelos formales para representación de conocimiento y razonamiento mediante lógicas temporales y espaciales.

Entre los resultados más recientes destacamos [6] donde se propone una lógica temporal de primer orden, *FTCLogic*, capaz de manejar restricciones temporales borrosas entre variables temporales. Se basa en la Lógica Posibilística e integra el modelo *FTCN* en un lenguaje independiente del dominio. Esto, además, la hace adecuada para una implementación práctica en dominios como la medicina.

Desde un punto de vista aplicado, en [7] se describen los pasos a seguir para la utilización de una lógica temporal para la representación de guías clínicas.

Varios trabajos tratan el problema de extender las lógicas temporales con el fin de obtener nuevas lógicas espaciales para razonar con direcciones cardinales entre regiones aproximadas por rectángulos. Por un lado, en [8] se utilizan las lógicas modales de intervalos para proponer nuevas lógicas modales de rectángulos. Por otro lado, en [9] y [10] se realiza una aproximación algebraica al problema utilizando técnicas de redes de restricciones cualitativas. Los modelos mencionados se han incorporado posteriormente a sistemas de ayuda a la decisión en entornos clínicos como se describirá en la Sec. III.

## II-C. Diagnóstico Temporal

Otra línea de trabajo del grupo se centra en el diagnóstico, entendiéndolo como un proceso para dar una explicación del comportamiento observado de un sistema a partir del conjunto de eventos observados.

Esta línea de trabajo se centra en diagnóstico temporal en medicina, modelando el comportamiento anormal donde se representan las relaciones causales y temporales entre los hallazgos anormales y las enfermedades. Estas relaciones se definen mediante unos *Patrones Diagnósticos Temporales Borrosos*. Cada patrón incluye (1) conocimiento sobre el contexto, que influye sobre la evolución temporal de una enfermedad (2) relaciones casuales y (3) relaciones temporales conformando una *FTCN* [11].

Además de la representación de modelos, se han desarrollado métodos de diagnóstico temporal. En [12] se describe este tipo de procesos en dos pasos. Primero, se construye mediante una estrategia abductiva una red causal (temporalmente consistente) a partir del conjunto de eventos observados. Segundo, algunas hipótesis son eliminadas de la red causal mediante un método de eliminación mediante poda conservativa.

Estos modelos mencionados se han implementado, desarrollando herramientas de adquisición de conocimiento (como CATEKAT) y aplicado al diagnóstico del Infarto Agudo de Miocardio en UCI [13].

## II-D. Razonamiento Basado en Casos Temporales

El Razonamiento Basado en Casos (CBR) es una metodología que tiene por objetivo resolver problemas a partir de problemas ya resueltos anteriormente. El grupo AIKE lleva

trabajando desde 2004 en una línea de trabajo centrada en CBR temporal donde los casos incluyen información temporal formando secuencias de eventos o redes de restricciones. En esta línea trasladamos de los modelos temporales descritos en la Sec. II-A al CBR y su posterior aplicación en el ámbito de la medicina. Entre los trabajos de investigación básica destacamos el desarrollo de funciones de similitud temporal que permiten la comparación y recuperación de casos como secuencias de eventos/puntos o intervalos [14], [15]. Hemos abordado el problema de casos que provienen de la ejecución de workflows y su aplicación a guías clínicas de infarto cerebral [16], [17]. También en el ámbito de la medicina el grupo AIKE ha trabajado en un sistema de recuperación de casos provenientes del historial clínico en una Unidad de Cuidados Intensivos [18].

En la actualidad estamos trabajando en el problema de reducción de casos temporales (análogo a la eliminación de instancias) [19], [20].

## II-E. Minería de Datos Temporales

La minería de datos temporales consiste en la extracción de patrones de los datos cuya importancia o significación es relevante de acuerdo a alguna medida. En la línea de investigación de AIKE hemos trabajado en la extracción de redes de restricciones difusas temporalmente consistentes que incluyen puntos e intervalos [21].

Con el objetivo de hacer algoritmos más eficientes, se ha limitado la forma de la red para obtener patrones secuenciales con relaciones entre puntos e intervalos en colaboración con la Antwerpen University [22]. En la tesis de Antonio Gomariz se ha incluido una representación de patrones que incluye un eficiente razonamiento temporal.

En trabajos posteriores hemos utilizado esos mismos patrones secuenciales multivariados para describir la evolución de los pacientes de una unidad de quemados, con el objetivo de predecir un devenir negativo que lleve al fallecimiento del paciente [23]. Se han evaluado diversas técnicas de discretización de series temporales y varios clasificadores asociativos que permiten explotar al máximo la capacidad predictiva de los patrones.

## II-F. Aprendizaje Computacional Evolutivo Multiobjetivo

La computación evolutiva multiobjetivo es actualmente un área de gran interés en la comunidad científica y está siendo aplicada con éxito en la mayoría de los procesos computacionales que implican múltiples objetivos, entre los que destacan los relacionados con el aprendizaje automático.

El grupo ha desarrollado y aplicado la computación evolutiva multi-objetivo en entornos de aprendizaje supervisado y no supervisado. Concretamente se han desarrollado algoritmos evolutivos multiobjetivo que han sido aplicados con éxito para las tareas de selección de atributos, selección de instancias, clasificación y regresión. En [24] el algoritmo ENORA desarrollado por el grupo se ha aplicado para selección de atributos en la clasificación de datos en centros de contacto con múltiples habilidades. En [25] ENORA se ha aplicado para

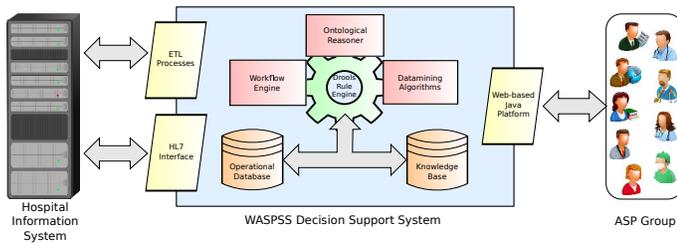


Figura 1. Arquitectura de WASPSS [29].

selección de atributos en tareas de regresión para la predicción de ventas on-line. En [26], [27] ENORA ha sido utilizado en este caso para la clasificación borrosa de la mortalidad por infección de pacientes quemados graves. Con respecto a aprendizaje no supervisado, el algoritmo ENORA se ha aplicado en [28] para, primero, selección de atributos de datos no clasificados sobre el comportamiento de niños en conjunción con la técnica de agrupamiento EM, y después, para la clasificación borrosa de la evaluación de su comportamiento.

### III. PROYECTOS RECIENTES REALIZADOS

#### III-A. Proyecto WASPSS

WASPSS<sup>2</sup>(TIN2013-45491-R) es un proyecto financiado por el MINECO en colaboración con clínicos del Hospital Universitario de Getafe pertenecientes a las especialidades de UCI, microbiología y farmacia. En este proyecto han participado 18 investigadores (14 especialistas en IA y 4 clínicos).

El proyecto WASPSS se centra en el problema de la aparición de multiresistencias. Esto ha llevado a los organismos internacionales y responsables de los servicios de salud a la definición de políticas que permitan mantener la eficacia de los antibióticos, paliando la generación de resistencias debidas a un consumo inadecuado. En concreto los organismos públicos han establecido programas de uso racional de los antibióticos, conocidos como Antimicrobial Stewardship Program (ASP). El equipo ASP es un grupo interdisciplinar de clínicos del hospital que definen acciones a llevar a cabo en todas las dimensiones del problema.

El desafío que ha abordado WASPSS es el diseño de una plataforma inteligente que permita ayudar a la gestión de un ASP en un hospital, abordando los procesos clínicos implicados de forma integrada. En concreto se ha abordado el desarrollo de técnicas y herramientas para: un modelo de inteligencia de negocio para ASP, el estudio de series temporales, apoyo a la decisión del tratamiento antibiótico y el soporte a la aplicación de guías clínicas.

El desarrollo de un sistema inteligente de estas características requiere de fuentes de datos y conocimiento provenientes de diferente ámbitos del hospital. En el proyecto hemos estudiado el impacto de los equipos ASP en los hospitales [30]–[32] y planteado una arquitectura que permite integrar y

<sup>2</sup><http://www.um.es/waspss/>

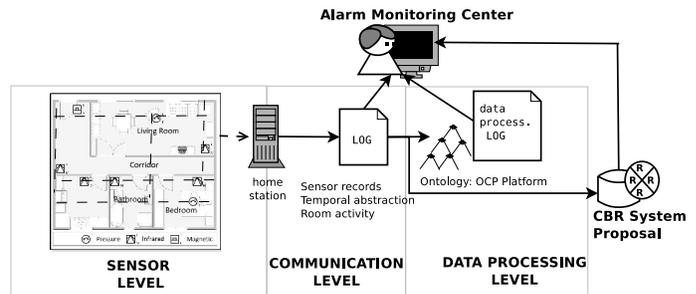


Figura 2. Arquitectura de sistema DAISY [41].

poner a disposición del resto de subsistemas de la información y conocimiento [33]–[35].

La toma de decisiones en antibiototerapia es compleja y depende tanto del antibiograma, de la historia clínica del paciente y los protocolos y guías clínicas. En este proyecto hemos desarrollado diferentes propuestas para la alerta en la prescripción [29], [36] y técnicas de visualización del antibiograma [37].

Las guías clínicas para el tratamiento antibiótico son herramientas esenciales para el médico, sin embargo su prescripción y dosificación dependen en parte de la epidemiología local. En el proyecto WASPSS nos hemos centrado tanto en la representación computacional de guías clínicas internacionales de referencia como de su ejecución a nivel local. Con este propósito hemos trabajado con modelos estándar de la industria como BPMN [38], [39], reglas de producción y modelos de la web semántica [40].

#### III-B. Proyecto DAISY

DAISY<sup>3</sup> (15277/PI/10), financiado por la Fundación Séneca de la Región de Murcia, investiga en sistemas de alarmas adaptativas y personalizadas en un entorno de monitorización en el hogar enfocado a dos poblaciones objetivo: riesgo en personas mayores que viven solas y personas mayores con Enfermedad de Alzheimer y/o Demencia Fronto Temporal. En este proyecto se ha contado con la colaboración de miembros de la Unidad de Demencias del Hospital Universitario Virgen de la Arrixaca siendo un total de 9 investigadores (7 especialistas en IA y 2 clínicos).

El principal objetivo del proyecto fue analizar la actividad de los ancianos en el hogar (logs) y proporcionar alarmas en función del comportamiento. Los avances científicos relacionados con el proyecto han sido en el ámbito del desarrollo de técnicas de CBR temporal y valoración de potenciales demencias. En la Fig. 2 se describe la arquitectura del sistema propuesto. En los problemas de generación temprana de alertas en dominios críticos, la componente temporal juega un papel fundamental. Así las técnicas de CBR, frente a la descripción a priori de situaciones de riesgo (reglas de alertas), proporcionan de forma integrada mecanismos efectivos para la detección de cambios de comportamiento del individuo de forma personalizada y favorecen la adaptabilidad y mantenimiento del sistema

<sup>3</sup><http://perseu.inf.um.es/~daisycbr/>

de una manera sencilla. Un primer problema a resolver ha sido el desarrollo tecnológico de herramientas de CBR temporal en colaboración con la West London University [42] donde se han implementando métricas de similitud descritas en la sección II-D. Un segundo desafío, debido al gran volumen de registros, ha sido el desarrollo de técnicas de reducción de casos (case-base maintenance) [20], [43]. Así, se ha desarrollado CELSEA<sup>4</sup>, una API de objetivo científico para el estudio de case-base maintenance [44]. Parte de estos resultados se han desarrollado en colaboración con investigadores de la Robert Gordon University [45].

Un segundo aspecto de este proyecto ha sido el estudio de la sospecha del deterioro cognitivo, en particular frente a la Enfermedad de Alzheimer y la Demencia Fronto-Temporal en colaboración con neuropsicólogos. El problema se ha abordado desde 2 frentes distintos. Por un lado de forma ubicua mediante el análisis de la actividad diaria con el objetivo de detectar caídas y comportamientos aberrantes que pudieran dar indicios de sufrir demencia. Así, se ha desarrollado técnicas de visual mining con el objetivo de detectar de una forma visual este tipo de comportamientos [46]. Por otro lado, se han desarrollado software para la evaluación neuropsicológica de forma ambulatoria, preprocesando la información y registrando los tiempos de respuesta [47], [48].

#### IV. CONCLUSIONES

Durante los últimos 25 años, el grupo de investigación AIKE ha trabajado en el campo de la Inteligencia Artificial para proponer soluciones en el ámbito de la salud tanto en modelos teóricos como en un desarrollo más aplicado.

Como eje vertebrador de la investigación consideramos que la dimensión temporal juega un papel fundamental en la resolución de tareas médicas. Por este motivo, el grupo AIKE ha centrado su investigación en el estudio de modelos formales de representación y razonamiento temporal desde diferentes puntos de vista (lógicas y álgebras, series temporales y secuencias, gestión fuzzy del tiempo, etc.).

El segundo eje de trabajo del grupo AIKE es el desarrollo de la IA en hospitales para dar apoyo al médico durante la práctica clínica. Para que las herramientas desarrolladas se implanten en el flujo de trabajo del clínico creemos que es fundamental: (a) un profundo conocimiento del problema clínico (adquiridos tras años de estrecha colaboración entre médicos e investigadores); (b) el desarrollo de software en producción en hospitales que dé valor añadido en el día a día e integre la información clave para su explotación; (c) usar modelos y técnicas de la IA que sean interpretables y validables por parte de los clínicos.

Finalmente, entre las líneas de trabajo y colaboración planificadas para los próximos años destacamos:

- Representación formal del conocimiento para definición de estrategias y protocolos clínicos.
- Propuesta y desarrollo de selección de parámetros clínicos mediante un enfoque de optimización multiobjetivo.

- Desarrollo de técnicas de fenotipado a partir de algoritmos de subgrupos y particionamiento.
- Estudio de técnicas de visualización para la mejora de la interpretabilidad médica de técnicas de aprendizaje.
- Comenzar una línea de trabajo sobre técnicas de predicción temporal aplicada a tratamientos y consumos.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad y fondos FEDER a través del proyecto WASPSS (Ref: TIN2013-45491-R)

#### REFERENCIAS

- [1] R. Marín, S. B. A. Bosch, and J. Mira, "Modeling time representation from a fuzzy perspective," *Cybernetics and Systems*, vol. 25, no. 2, pp. 207–215, 1994.
- [2] R. Marín, M. A. Cárdenas, M. Balsa, and J. L. Sánchez, "Obtaining solutions in fuzzy constraint networks," *International Journal of Approximate Reasoning*, vol. 3-4, pp. 261–288, 1996.
- [3] M. C. Martínez, J. M. Juárez, J. T. Palma, R. Marín, and F. Palacios, "Avian influenza: Temporal modeling of a human to human transmission case," *Expert Syst. Appl.*, vol. 38, no. 7, pp. 8865–8885, 2011.
- [4] M. Campos, J. M. Juárez, J. Salort, J. T. Palma, and R. Marín, "Reasoning in dynamic systems: From raw data to temporal abstract information," *Neurocomputing*, vol. 72, no. 4-6, pp. 871–878, 2009.
- [5] M. C. Martínez, J. M. Juárez, J. T. Palma, and R. Marín, "Using temporal constraints for temporal abstraction," *J. Intell. Inf. Syst.*, vol. 34, no. 1, pp. 57–92, 2010.
- [6] M. Cardenas-Videma and R. Marín, "FTCLoGic: Fuzzy temporal constraint logic," *Fuzzy Set and Systems*, vol. (accepted), 2018.
- [7] G. Sciavicco, J. M. Juárez, and M. Campos, "Quality checking of medical guidelines using interval temporal logics: A case-study," in *IWINAC (2)*, ser. Lecture Notes in Computer Science, vol. 5602. Springer, 2009, pp. 158–167.
- [8] A. Morales, I. Navarrete, and G. Sciavicco, "A new modal logic for reasoning about space: spatial propositional neighborhood logic," *Ann. Math. Artif. Intell.*, vol. 51, no. 1, pp. 1–25, 2007.
- [9] I. Navarrete, A. Morales, and G. Sciavicco, "Consistency checking of basic cardinal constraints over connected regions," in *Proceedings of IJCAI*, 2007, pp. 495–500.
- [10] I. Navarrete, A. Morales, G. Sciavicco, and M. A. C. Viedma, "Spatial reasoning with rectangular cardinal relations - the convex tractable subalgebra," *Ann. Math. Artif. Intell.*, vol. 67, no. 1, pp. 31–70, 2013.
- [11] J. T. Palma, J. M. Juárez, M. Campos, and R. Marín, "A fuzzy approach to temporal model-based diagnosis for intensive care units," in *ECAI. IOS Press*, 2004, pp. 868–872.
- [12] J. T. Palma, J. M. Juárez, M. Campos, and R. Marín, "Fuzzy theory approach for temporal model-based diagnosis: An application to medical domains," *Artificial Intelligence in Medicine*, vol. 38, no. 2, pp. 197–218, 2006.
- [13] J. M. Juárez, M. Campos, J. T. Palma, and R. Marín, "Computing context-dependent temporal diagnosis in complex domains," *Expert Syst. Appl.*, vol. 35, no. 3, pp. 991–1010, 2008.
- [14] J. M. Juárez, F. Guil, J. T. Palma, and R. Marín, "Temporal similarity by measuring possibilistic uncertainty in CBR," *Fuzzy Sets and Systems*, vol. 160, no. 2, pp. 214–230, 2009.
- [15] Z. Huang, J. M. Juárez, W. Dong, L. Ji, and H. Duan, "Predictive monitoring of local anomalies in clinical treatment processes," in *AIME*, ser. LNCS, vol. 9105. Springer, 2015, pp. 25–34.
- [16] C. Combi, M. Gozzi, J. M. Juárez, R. Marín, and B. Oliboni, "Querying clinical workflows by temporal similarity," in *AIME*, ser. Lecture Notes in Computer Science, vol. 4594. Springer, 2007, pp. 469–478.
- [17] C. Combi, M. Gozzi, B. Oliboni, J. M. Juárez, and R. Marín, "Temporal similarity measures for querying clinical workflows," *Artificial Intelligence in Medicine*, vol. 46, no. 1, pp. 37–54, 2009.
- [18] J. M. Juárez, J. Salort, J. T. Palma, and R. Marín, "Case representation ontology for case retrieval systems in medical domains," in *Artificial Intelligence and Applications*. IASTED/ACTA Press, 2007, pp. 188–193.

<sup>4</sup><http://perseo.inf.um.es/~aike/celsea/>



- [19] J. M. Juárez, S. Craw, J. R. Lopez, and M. Campos, "Maintenance of case bases: Current algorithms after fifty years," in *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, ser. IJCAI'18, 2018, pp. 5458–5463.
- [20] E. Lupiani, J. M. Juárez, and J. T. Palma, "Evaluating case-base maintenance algorithms," *Knowl.-Based Syst.*, vol. 67, pp. 180–194, 2014.
- [21] M. Campos, J. T. Palma, and R. Marín, "Temporal data mining with temporal constraints," in *AIME*, ser. Lecture Notes in Computer Science, vol. 4594. Springer, 2007, pp. 67–76.
- [22] P. Fournier-Viger, A. Gomariz, M. Campos, and R. Thomas, "Fast vertical mining of sequential patterns using co-occurrence information," in *PAKDD (I)*, ser. Lecture Notes in Computer Science, vol. 8443. Springer, 2014, pp. 40–52.
- [23] I. J. Casanova, M. Campos, J. M. Juárez, A. Fernandez-Fernandez-Arroyo, and J. A. Lorente, "Using multivariate sequential patterns to improve survival prediction in intensive care burn unit," in *AIME*, ser. Lecture Notes in Computer Science, vol. 9105. Springer, 2015, pp. 277–286.
- [24] F. Jiménez, E. Marzano, G. Sánchez, G. Sciavicco, and N. Vitacolonna, "Attribute selection via multi-objective evolutionary computation applied to multi-skill contact center data classification," in *SSCI*. IEEE, 2015, pp. 488–495.
- [25] F. Jiménez, G. Sánchez, J. M. García, G. Sciavicco, and L. M. Pechuán, "Multi-objective evolutionary feature selection for online sales forecasting," *Neurocomputing*, vol. 234, pp. 75–92, 2017.
- [26] F. Jiménez, G. Sánchez, and J. M. Juárez, "Multi-objective evolutionary algorithms for fuzzy classification in survival prediction," *Artificial Intelligence in Medicine*, vol. 60, no. 3, pp. 197 – 219, 2014. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0933365713001668>
- [27] F. Jiménez, G. Sánchez, J. M. Juárez, J. M. Alcaraz, and J. F. Sánchez, "Fuzzy classification of mortality by infection of severe burnt patients using multiobjective evolutionary algorithms," in *IWINAC (I)*, ser. Lecture Notes in Computer Science, vol. 5601. Springer, 2009, pp. 447–456.
- [28] F. Jiménez, R. Jódar, M. del Pilar Martín, G. Sánchez, and G. Sciavicco, "Unsupervised feature selection for interpretable classification in behavioral assessment of children," *Expert Systems*, vol. 34, no. 4, 2017.
- [29] B. Cánovas-Segura, M. Campos, A. M. Nicolas, J. M. Juárez, and F. Palacios, "Development of a clinical decision support system for antibiotic management in a hospital environment," *Progress in Artificial Intelligence*, vol. 5, no. 3, pp. 181–197, 2016.
- [30] A. M. Vázquez, J. G. Septiem, I. J. T. Vassallo, D. Sanz-Rosa, M. C. Martínez, M. E. Martínez, F. P. Ortega, and J. M. J. Navalón, "Programa de optimización de antibióticos en un servicio de cirugía general y digestiva: efecto sobre prescripción de meropenem en sus dos primeros de implantación programa de optimización de antibióticos en un servicio de cirugía general y digestiva: efecto sobre prescripción de meropenem en sus dos primeros de implantación," *Revista de Cirugía Española*, vol. 94, no. Noviembre 2016, p. 135, November 2016.
- [31] J. G. Septiem, M. E. Martínez, A. M. Vázquez, F. Palacios, Á. S. Grande, C. B. Recuenco, and J. M. J. Navalón, "Impacto de implantación del programa proa (programa de racionalización y optimización del uso de antimicrobianos) en un servicio de cirugía general y digestivo," *Revista de Cirugía Española*, vol. 94, no. Noviembre 2016, p. 126, November 2016.
- [32] A. Manuel-Vázquez, F. Palacios-Ortega, J. García-Septiem, I. J. This-sard, D. Sanz-Rosa, J. Arias-Díaz, J. M. Jover-Navalón, and J. M. Ramia, "Antimicrobial stewardship program in a department of surgery: human, electronic and methodological resources. results after three years," *Annals of Surgery*, vol. (under evaluation), 2018.
- [33] F. Palacios, M. Campos, J. M. Juárez, S. E. Cosgrove, E. Avdic, B. Cánovas-Segura, A. Morales, M. E. Martínez-Nuñez, T. Molina-García, P. García-Hierro, and J. Cacho-Calvo, "A clinical decision support system for an Antimicrobial Stewardship Program," in *HEALTHINF 2016 - 9th International Conference on Health Informatics, Proceedings*. Rome: SciTePress, 2016, pp. 496–501.
- [34] M. Campos, B. Garcia, J. M. Juárez, J. M. Guillamon, and F. Palacios, "What do doctors need for effective adoption and integration of clinical guidelines into daily practice?" in *ICHI*. IEEE Computer Society, 2014, pp. 247–255.
- [35] A. Morales, B. Cánovas-Segura, M. Campos, J. M. Juárez, and F. Palacios, "Proposal of a Big Data Platform for Intelligent Antibiotic Surveillance in a Hospital," in *Advances in Artificial Intelligence: 17th Conference of the Spanish Association for Artificial Intelligence, CAEPIA 2016, Salamanca, Spain, September 14-16, 2016. Proceedings*, O. Luaces, J. A. Gámez, E. Barrenechea, A. Troncoso, M. Galar, H. Quintián, and E. Corchado, Eds., 2016, pp. 261–270.
- [36] A. Morales, M. Campos, J. M. Juárez, B. Canovas-Segura, F. Palacios, and R. Marin, "A decision support system for antibiotic prescription based on local cumulative antibiograms," *J. of Biomedical Informatics*, vol. 84, pp. 114–122, 2018.
- [37] H. Garcia-Caballero, M. Campos, J. M. Juárez, and F. Palacios, "Visualization in clinical decision support system for antibiotic treatment," in *Proceedings of the Conference of Spanish Society on Artificial Intelligence (CAEPIA15)*, 2015, pp. 71–80.
- [38] B. Cánovas-Segura, F. Zerbato, B. Oliboni, C. Combi, M. Campos, A. Morales, J. M. Juárez, R. Marin, and F. Palacios, "A process-oriented approach for supporting clinical decisions for infection management," in *2017 IEEE International Conference on Healthcare Informatics (ICHI)*, Aug 2017, pp. 91–100.
- [39] B. Cánovas-Segura, F. Zerbato, B. Oliboni, C. Combi, M. Campos, A. M. Nicolás, J. M. Juárez, F. Palacios, and R. Marín, "A decision support visualization tool for infection management based on BMPN and DMN," in *CITI*, ser. Communications in Computer and Information Science, vol. 749. Springer, 2017, pp. 158–168.
- [40] N. Iglesias, J. M. Juárez, M. Campos, and F. Palacios, "Computable representation of antimicrobial recommendations using clinical rules: A clinical information systems perspective," in *IWINAC (I)*, ser. Lecture Notes in Computer Science, vol. 9107. Springer, 2015, pp. 258–268.
- [41] E. Lupiani, J. M. Juárez, J. Palma, and R. Marin, "Monitoring elderly people at home with temporal case-based reasoning," *Knowledge-Based Systems*, vol. 134, pp. 116 – 134, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0950705117303477>
- [42] E. Lupiani, J. M. Juárez, J. T. Palma, C. S. Sauer, and T. Roth-Berghofer, "Using case-based reasoning to detect risk scenarios of elderly people living alone at home," in *ICCB*, ser. Lecture Notes in Computer Science, vol. 8765. Springer, 2014, pp. 274–288.
- [43] E. Lupiani, J. M. Juárez, and J. T. Palma, "A proposal of temporal case-base maintenance algorithms," in *ICCB*, ser. Lecture Notes in Computer Science, vol. 8765. Springer, 2014, pp. 260–273.
- [44] E. Lupiani, J. M. Juárez, F. Jiménez, and J. T. Palma, "Evaluating case selection algorithms for analogical reasoning systems," in *IWINAC (I)*, ser. Lecture Notes in Computer Science, vol. 6686. Springer, 2011, pp. 344–353.
- [45] E. Lupiani, S. Craw, S. Massie, J. M. Juárez, and J. T. Palma, "A multi-objective evolutionary algorithm fitness function for case-base maintenance," in *ICCB*, ser. Lecture Notes in Computer Science, vol. 7969. Springer, 2013, pp. 218–232.
- [46] J. M. Juárez, J. M. Ochotorena, M. Campos, and C. Combi, "Multiple temporal axes for visualising the behaviour of elders living alone," in *ICHI*. IEEE Computer Society, 2013, pp. 387–395.
- [47] J. M. Juárez, G. García-Fernandez, M. Campos, B. Martínez, M. Antequera, and C. Antunez, "Experiences on computerised neuropsychological tests for dementia using a mobile touchable interface," in *ICHI*. IEEE Computer Society, 2014, pp. 355–361.
- [48] M. M. Antequera, M. T. Daza, F. Guil, J. M. Juárez, and G. López-Crespo, "An architecture proposal for adaptive neuropsychological assessment," in *IWINAC (I)*, ser. Lecture Notes in Computer Science, vol. 5601. Springer, 2009, pp. 426–436.



**IV Jornadas de Fusión de  
la Información y  
Ensemble Learning  
(IV FINO)**

EMILIO CORCHADO

MIKEL GALAR

BRUNO BARUQUE

ALBERTO FERNÁNDEZ







# Measuring Diversity and Accuracy in ANN Ensembles\*

\***Note:** The full contents of this paper have been published in the volume *Lecture Notes in Artificial Intelligence 11160* (LNAI 11160)

M. P. Sesmero

*Universidad Carlos III de Madrid*  
Madrid, Spain  
msesmero@inf.uc3m.es

J. M. Alonso-Weber

*Universidad Carlos III de Madrid* Madrid, Spain  
jmaw@ia.uc3m.es

A. Giuliani

*Università di Cagliari*  
Cagliari, Italy  
alessandro.giuliani@diee.unica.it

G. Armano

*Università di Cagliari*  
Cagliari, Italy  
armano@diee.unica.it

A. Sanchis

*Universidad Carlos III de Madrid*  
Madrid, Spain  
masm@inf.uc3m.es

**Abstract**—Performance of classifier ensembles depends on the precision and on the diversity of the members of the ensemble. In this paper we present an experimental study in which the relationship between the accuracy of the ensemble and both the diversity and the accuracy of base learners is analyzed. We conduct experiments on 8 different ANN ensembles and on 5 multiclass data sets. Experimental results show that a high diversity degree among the base learners does not always imply a high accuracy in the ensemble.

**Index Terms**—Ensemble of classifiers, Diversity, Accuracy, ANN

# Medidas difusas para la combinación de ensembles: una primera aproximación utilizando el rendimiento en conjuntos de datos altamente desequilibrados

M. Uriz, D. Paternain, H. Bustince, M. Galar

*Departamento de Estadística, Informática y Matemáticas, Universidad Pública de Navarra,*

Campus Arrosadía s/n, 31006 Pamplona, España

{mikelxabier.uriz, daniel.paternain, bustince, mikel.galar}@unavarra.es

**Resumen**—En este trabajo estudiamos la posibilidad de aprender medidas difusas basándonos en el rendimiento de los clasificadores para mejorar las funciones de agregación tradicionales utilizadas en los ensembles de clasificadores. Las medidas difusas son funciones “conjunto-valor”, no necesariamente aditivas, y son la base para la construcción de las integrales difusas no lineales, como las integrales de Choquet y de Sugeno. Nuestra hipótesis es que teniendo en cuenta las interacciones entre los miembros del ensemble podemos llegar a un mejor rendimiento. Precisamente, las medidas difusas nos permiten modelar dichas interacciones. Nuestra propuesta consiste en obtener la medida difusa directamente de los datos considerando el rendimiento de cada subconjunto de clasificadores del ensemble. De esta manera, no necesitamos incluir otros métodos de aprendizaje para la medida difusa que nos pueden llevar a un sobre-ajuste. Para verificar la utilidad de la medida propuesta, consideraremos 33 conjuntos de datos altamente desequilibrados y desarrollaremos un estudio experimental completo comparando nuestra propuesta con otros métodos considerados comúnmente en la literatura.

**Index Terms**—Agregaciones, Medidas Difusas, Clasificación, Ensembles, Datasets no balanceados

## I. INTRODUCCIÓN

Los ensembles de clasificadores [1] son conocidos por ser una buena alternativa para mejorar el rendimiento de un único clasificador utilizando una combinación de varios clasificadores. En los ensembles, se espera que los clasificadores individuales que forman el ensemble tengan diversidad, de tal manera que su combinación nos lleve a una mejora de los resultados. Sin la diversidad, todos los clasificadores llegarían a las mismas respuestas y por lo tanto, su combinación sería la misma que si se considerarían por separado.

A la hora de construir un ensemble para un problema específico, hay que tener en cuenta dos aspectos importantes: 1) cómo generar diversidad entre clasificadores; 2) cómo combinar la decisión de todos los clasificadores en una única salida. Aunque ambos aspectos son importantes para el rendimiento final del ensemble, el primero ha recibido más atención en la literatura y se han desarrollado varias formas de conseguir la diversidad, siendo Bagging [2] y Boosting [3] los más populares. Esto es debido a que se esperan mayores mejoras cambiando los clasificadores subyacentes que combinando sus salidas de diferentes formas. Sin embargo, no se puede pasar por alto la importancia de cómo se fusionan las salidas. Aunque la ganancia en rendimiento puede ser menor, se puede

utilizar el conocimiento adquirido por cada clasificador para llevar a cabo una mejor combinación que simplemente utilizar la media aritmética.

En este artículo pretendemos mejorar el rendimiento de los ensembles solo modificando la fase de combinación. Obviamente, se han desarrollado varios métodos con este propósito, p.e., el voto ponderado, la combinación de Naive Bayes o los Decision Templates entre otros [1]. A diferencia de estos, nosotros nos centraremos en entender cómo colabora cada clasificador con el resto. Es decir, intentaremos modelar las coaliciones o intersecciones (positivas o negativas) que pueden formar dependiendo de su rendimiento. Para modelar este comportamiento, consideramos el uso de las medidas difusas y las integrales difusas [4], [5]. Debemos hacer notar que aunque estas han sido utilizadas anteriormente para la combinación de clasificadores, todo su potencial no ha sido explotado, dada la limitación impuesta es su construcción [6], [7].

Las dos funciones de agregación basadas en medidas difusas más utilizadas son las integrales de Choquet [8] y Sugeno [9]. Ambas permiten agregar o fusionar información cuantitativa teniendo en cuenta la interacción entre los datos mediante medias de la medida difusa asociada. De esta manera, esta familia de funciones de agregación pueden ser más potentes que el resto de agregaciones más comunes, como la media ponderada o los operadores OWA.

Por consiguiente, nuestra propuesta consiste en el uso de integrales difusas conjuntamente con medidas difusas para realizar la combinación de clasificadores. Para ello proponemos una nueva forma de obtener las medidas difusas a partir del rendimiento de cada clasificador, el cual refleja mejor como interaccionan realmente.

A fin de estudiar empíricamente la utilidad de la construcción de la medida difusa propuesta, hemos considerado el problema de las clases no balanceadas y los ensembles específicamente diseñados para atacar este problema [10]. Más concretamente, nos centramos en UnderBagging [11]. El estudio experimental se ha realizado sobre los 33 conjuntos de datos con mayor ratio de desequilibrio (no balanceo) del repositorio de KEEL [12]. Compararemos nuestra propuesta con el uso de otras funciones de agregación existentes para la combinación de clasificadores como las agregaciones ponderadas o las medidas difusas lambda [6], [7].



El resto del artículo está organizado de la siguiente manera. En la Sección II, recordamos la teoría de las funciones de agregación necesaria para comprender el resto del trabajo. Después, la Sección III introduce los ensembles, las diferentes maneras de combinar clasificadores y las soluciones adaptadas para el problema del no balanceo. En la Sección IV, describimos cómo establecer los parámetros de las agregaciones ponderadas y también nuestra propuesta para la creación de la medida difusa. Las Secciones V y VI, explican el marco de trabajo experimental considerado para este estudio y analizan los resultados obtenidos. Finalmente, la sección VII concluye este trabajo.

## II. FUNCIONES DE AGREGACIÓN

En esta sección recordamos varios conceptos sobre las funciones de agregación que van a ser usadas para agregar las salidas de los ensembles. Los operadores de agregación o las funciones de agregación son una herramienta matemática que se han vuelto esencial para los problemas de fusión de información. En la literatura es muy fácil encontrar monografías completas que cubren varias familias de funciones de agregación, como las t-normas, t-conormas, medias, integrales, etc. (ver por ejemplo [13]–[16]).

Recordamos la definición usual de una función de agregación (en este trabajo nos centramos en el intervalo unitario).

*Definition 1:* Un mapeo  $f : [0, 1]^n \rightarrow [0, 1]$  es llamada función de agregación si satisface  $f(0, \dots, 0) = 0$ ,  $f(1, \dots, 1) = 1$  y monotonía creciente, p.ej., si  $x_i \leq y_i$  para todo  $i \in \{1, \dots, n\}$ , entonces  $f(x_1, \dots, x_n) \leq f(y_1, \dots, y_n)$ .

*Observación:* en la literatura reciente, la propiedad de monotonía de las funciones de agregación ha sido extendida o generalizada (ver por ejemplo [17], [18]).

En este trabajo, solo nos centraremos en las funciones de agregación con comportamiento promediado, también llamadas *medias*. Estas funciones cumplen que  $\min(x_1, \dots, x_n) \leq f(x_1, \dots, x_n) \leq \max(x_1, \dots, x_n)$  para todo  $(x_1, \dots, x_n) \in [0, 1]^n$ . Observar también que, debido a la monotonía, el comportamiento promedio es equivalente al comportamiento idempotente, es decir,  $f(x, \dots, x) = x$  para todo  $x \in [0, 1]$ .

Ejemplos bien conocidos de funciones de agregación promediadas son las siguientes:

- La media aritmética  $AM(x_1, \dots, x_n) = \frac{1}{n}(x_1 + \dots + x_n)$ ;
- La mediana

$$MED(x_1, \dots, x_n) = \begin{cases} \frac{1}{2}(x_{(k)} + x_{(k+1)}) & \text{si } n = 2k \\ x_{(k)} & \text{si } n = 2k - 1 \end{cases}$$

con  $k \in \mathbb{N}^+$  y  $x_{(k)}$  siendo  $k$  el elemento más largo (más pequeño) de  $x_1, \dots, x_n$ ;

- La media geométrica  $GM(x_1, \dots, x_n) = \sqrt[n]{x_1 x_2 \dots x_n}$ ;
- La media armónica  $HM(x_1, \dots, x_n) = \frac{n}{\frac{1}{x_1} + \dots + \frac{1}{x_n}}$ .

Cabe decir que cuando se aplican las funciones de fusión de información en un problema del mundo real, se deben incorporar algunas fuentes de información (en adición a las propias entradas). Esto se puede hacer de manera sencilla aplicando funciones de agregación ponderadas, dado que los

pesos nos permiten modelar la importancia de cada atributo o criterio a ser fusionado.

*Definition 2:* Un vector  $\mathbf{W} = (w_1, \dots, w_n)$  es un vector de ponderación si  $w_i \in [0, 1]$  y  $\sum_{i=1}^n w_i = 1$ .

A partir de la definición del vector de ponderación podemos definir fácilmente la media aritmética ponderada como  $AM_{\mathbf{w}}(x_1, \dots, x_n) = \sum_{i=1}^n w_i x_i$ . Observar que cuando incorporamos el vector de ponderación se pierde la simetría de la media aritmética.

Otra familia importante de funciones de agregación ponderadas son los operadores OWA. En este caso, los pesos no son asociados con una entrada particular (criterio) sino con su magnitud. Por lo tanto, los operadores OWA son funciones de agregación simétricas. Dado un vector de pesos  $\mathbf{W}$ , el operador OWA es definido como  $OWA_{\mathbf{w}}(x_1, \dots, x_n) = \sum_{i=1}^n w_i x_{(i)}$  donde  $x_{(i)}$  es el elemento  $i$  más largo de  $x_1, \dots, x_n$ .

### II-A. De funciones de agregación ponderadas a basadas en medidas

Como ya hemos mencionado, los vectores de pesos son utilizados para dar importancia a cada entrada individual. Sin embargo, cuando trabajamos con problemas complejos, cada entrada (criterio, atributo o fuente de información) no está totalmente aislada del resto de entradas. Esto quiere decir que claramente podemos tener interacciones positivas o negativas entre entradas. Un herramienta adecuada para modelar esta interacción son las medidas difusas (no aditivas) [19].

*Definition 3:* Sea  $\mathcal{N} = \{1, \dots, n\}$ . Una medida difusa discreta es una función  $m : 2^{\mathcal{N}} \rightarrow [0, 1]$  que satisface las condiciones de frontera  $m(\emptyset) = 0$ ,  $m(\mathcal{N}) = 1$  y de monotonía, p.ej.  $m(A) \leq m(B)$  siempre que  $A \subset B$  para todo  $A, B \subseteq \mathcal{N}$ .

Para definir una medida difusa es necesario establecer sus  $2^n - 2$  componentes. Esto puede ser una tarea compleja cuando  $n$  es bastante grande, por lo tanto, en la literatura se pueden encontrar varias simplificaciones. Una de las más conocidas son las  $\lambda$  medidas de Sugeno [9].

*Definition 4:* Sea  $\lambda \in (-1, \infty)$ . Podemos decir que  $m : 2^{\mathcal{N}} \rightarrow [0, 1]$  es una  $\lambda$  medida de Sugeno si, para todo  $A, B \subseteq \mathcal{N}$  con  $A \cap B = \emptyset$ , entonces  $m(A \cup B) = m(A) + m(B) + \lambda m(A)m(B)$ .

Un paso más allá en la modelación del conocimiento en la fusión de información son las integrales difusas, como la integral de Choquet o la integral de Sugeno, que están basadas en medidas difusas.

*Definition 5:* Dada una medida difusa  $m : 2^{\mathcal{N}} \rightarrow [0, 1]$ , la integral discreta de Choquet es dada por

$$C_m(x_1, \dots, x_n) = \sum_{i=1}^n (x_{\sigma(i)} - x_{\sigma(i-1)}) m(\{\sigma(i), \dots, \sigma(n)\})$$

donde  $\sigma : \mathcal{N} \rightarrow \mathcal{N}$  es una permutación tal que  $x_{\sigma(1)} \leq \dots \leq x_{\sigma(n)}$ .

Observar que si  $m$  es aditiva, p. ej. para todo  $A, B \subset \mathcal{N}$ ,  $A \cap B = \emptyset$  entonces  $m(A \cup B) = m(A) + m(B)$ , la integral de Choquet es la media aritmética ponderada. Si  $m$  es simétrica, p. ej. para cualquier  $A, B \subseteq \mathcal{N}$ ,  $m(A) = m(B)$  donde  $|A| =$

$|B|$ , entonces la integral de Choquet es un operador OWA. Finalmente, si  $m$  es simétrica y aditiva, entonces la integral de Choquet es la media aritmética.

*Definition 6:* Dada una medida difusa  $m : 2^{\mathcal{N}} \rightarrow [0, 1]$ , la integral discreta de Sugeno es dada por

$$S_m(x_1, \dots, x_n) = \max_{i=1}^n \min\{x_{\sigma(i)}, m(\{\sigma(i), \dots, \sigma(n)\})\}$$

donde  $\sigma : \mathcal{N} \rightarrow \mathcal{N}$  es una permutación tal que  $x_{\sigma(1)} \leq \dots \leq x_{\sigma(n)}$ .

### III. ENSEMBLES Y EL PROBLEMA DE LAS CLASES NO BALANCEADAS

En esta sección introduciremos los ensembles y el problema de las clases no balanceadas en el cual nos centramos en este trabajo.

#### III-A. Ensembles: construcción y agregación

Los ensembles están compuestos por un número de clasificadores y su objetivo principal es mejorar el rendimiento de los clasificadores individuales. No hay mejora posible cuando se combina el mismo clasificador y por tanto, se requieren formas de construir diferentes clasificadores a partir de los datos originales. Una vez estos clasificadores han sido entrenados, los nuevos ejemplos son clasificados sometiéndolos a todos los clasificadores y combinando sus salidas obteniendo la clase final para los ejemplos no etiquetados. La fase de la combinación también es conocida como fusión o agregación [1]. Este trabajo se centra en este aspecto de los ensembles de clasificadores, aunque primero tenemos que presentar como crear los diferentes clasificadores antes de pasar por su combinación.

Existen varios métodos para construir los ensembles de clasificadores, los cuales se centran principalmente en crear clasificadores base con un buen balance entre precisión y diversidad. Entre ellos, los algoritmos de aprendizaje más utilizados son AdaBoost [3] y Bagging [2]. En ambos casos, los clasificadores son entrenados estratégicamente con el objetivo de conseguir la diversidad requerida.

Breiman [2] propuso el algoritmo Bagging, un método simple pero efectivo para construir ensembles. En este método, cada clasificador es entrenado con un subconjunto diferente de los datos originales. Por lo tanto, se utiliza un nuevo conjunto de datos para construir cada clasificador muestreando aleatoriamente (con reemplazo) ejemplos del conjunto original.

A la hora de clasificar nuevos ejemplos, se tienen en cuenta las salidas de todos los clasificadores. Normalmente, para obtener la clase final se utiliza la mayoría o la mayoría ponderada (donde se considera la confianza devuelta por el clasificador). La salida se obtiene utilizando la siguiente fórmula:

$$H(x) = I\left(\frac{1}{T} \sum_{t=1}^T h_t(x) > \theta\right) \quad (1)$$

donde  $h_t \in [0, 1]$  son los clasificadores inducidos,  $I$  es la función indicador (devuelve 1 si la condición es satisfecha y 0 en otro caso) y  $\theta$  es el umbral para decidir la clase (normalmente

$\theta = 0,5$ ). Asumiendo que cada clasificador devuelve la confianza de su predicción (que se puede interpretar como la probabilidad de que el ejemplo pertenezca a la clase 1), esta fórmula simplemente refleja que esas predicciones son promediadas obteniendo la probabilidad media de que el ejemplo pertenezca a la clase 1 (es por ello que normalmente se considera  $\theta = 0,5$ ). Esto es comúnmente conocido como la mayoría ponderada, mientras que el voto mayoritario se considera cuando  $h_t \in \{0, 1\}$ .

Se ve claramente que la fórmula de promediado puede ser cambiada por cualquier otra fórmula presentada en la sección anterior. De hecho este es nuestro interés en este artículo. Tratamos de mejorar esta combinación teniendo en cuenta las interacciones de los clasificadores. Para ello, compararemos el uso de diferentes funciones de agregación: las no ponderadas (medias aritmética, geométrica y armónica), las ponderadas (media aritmética ponderada y los OWA) y los basados en medidas (Choquet y Sugeno). Obviamente, las últimas agregaciones son las que tienen en cuenta las interacciones, mientras que las no ponderadas directamente combinan las diferentes probabilidades y las ponderadas utilizan un único peso por cada clasificador. En el caso de las agregaciones ponderadas y las basadas en medidas, el establecer sus parámetros es clave. Este asunto se explica en la sección IV, donde proponemos una nueva forma de construir las medidas difusas a partir del rendimiento de los clasificadores.

#### III-B. El problema de las clases no balanceadas

Siempre que el número de ejemplos de cada clase no sean parecidos, el conjunto de datos va a estar desequilibrado. Centrándonos en los problemas de dos clases, el problema es que una clase está infrarrepresentada aunque desde el punto de vista del aprendizaje, esta suele tener mayor importancia [20]. En este contexto, los algoritmos de aprendizaje estándares tienden a posicionar sus clasificaciones hacia la clase mayoritaria, dado a su diseño orientado a precisión.

Existen diferentes métodos lidiar con el problema de las clases no balanceadas. En este trabajo no hemos centrado en las soluciones basadas en ensembles [10], y más concretamente, en el método conocido como UnderBagging [11] debido a su buen comportamiento. UnderBagging funciona introduciendo un re-muestreo aleatorio en cada iteración para crear un conjunto de datos (bolsa) balanceado. Por lo tanto, una bolsa es creada eliminando aleatoriamente ejemplos de la clase mayoritaria hasta tener un conjunto balanceado.

Otra cuestión importante cuando se trabaja con distribuciones de clases no balanceadas, es cómo medir la calidad del clasificador. En este escenario la precisión ya no es una medida válida ya que no es capaz de reflejar la precisión de ambas clases. Por esta razón, normalmente se construye la matriz de confusión de la cual se pueden obtener diferentes medidas. Entre ellas, el Ratio de Verdaderos Positivos ( $TP_{rate} = \frac{TP}{TP+FN}$ ) y el Ratio de Verdaderos Negativos ( $TN_{rate} = \frac{TN}{FP+TN}$ ) permiten medir la calidad de la clasificación para clase por separado. Sin embargo, para ser capaces de comparar dos métodos, normalmente se prefiere evaluar el rendimiento de



ambas clases al mismo tiempo. Para ello, se puede utilizar la media geométrica (GM) [21], la cual se muestra en (2).

$$GM = \sqrt{TP_{rate} \cdot TN_{rate}}. \quad (2)$$

#### IV. ESTABLECIENDO LOS PESOS Y LAS MEDIDAS DIFUSAS EN BASE AL RENDIMIENTO DE LOS CLASIFICADORES

En esta sección presentamos el método seguido para establecer los parámetros de las funciones de agregación. Primero explicaremos como se calculan los pesos para la media aritmética ponderada y los OWA. Después presentaremos nuestra propuesta para el cálculo de la medida difusa basándonos en el rendimiento de los clasificadores.

##### IV-A. Pesos para las agregaciones ponderadas

Primero explicaremos cómo calcular los vectores de pesos para los operadores OWA. Recordar que para estas funciones, los pesos modelan la importancia de la magnitud de cada entrada. En este trabajo hemos seguido la metodología descrita en [22], donde los pesos son obtenidos por un cuantificador difuso  $Q : [0, 1] \rightarrow [0, 1]$  utilizando la fórmula  $w_i = Q\left(\frac{i}{n}\right) - Q\left(\frac{i-1}{n}\right)$  para todo  $i \in \{1, \dots, n\}$ . Hemos utilizado tres cuantificadores lineales diferentes:  $Q_{alh}$  con  $a = 0, b = 0,5$ ,  $Q_{amap}$  con  $a = 0,5, b = 1,0$  y  $Q_{mot}$  con  $a = 0,3, b = 0,8$ , que son calculados por:

$$Q(x) = \begin{cases} 0 & x < a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & x > b \end{cases}$$

En el caso de la media aritmética ponderada, se incorpora conocimiento del problema que estamos tratando de resolver en el vector de pesos. Para ello, establecemos cada peso de cada clasificador utilizando el rendimiento normalizado obtenido por cada clasificador sobre el conjunto de entrenamiento. Por ejemplo, si  $Per_1, \dots, Per_n$  son los rendimientos de cada uno de los  $n$  clasificadores, entonces  $w_i = \frac{Per_i}{\sum_{j=1}^n Per_j}$  para todo  $i \in \{1, \dots, n\}$ . Dado que nos hemos centrado en conjuntos de datos no balanceados, utilizamos la GM como medida de rendimiento para modelar mejor la calidad de cada clasificador. Observar que en este caso, solo se tiene en cuenta la calidad individual de cada clasificador, y no se utiliza información sobre como interaccionan entre ellos.

##### IV-B. Propuesta para la construcción de la medida difusa

Para las integrales de Choquet y Sugeno necesitamos construir una medida difusa  $m : 2^{\mathcal{N}} \rightarrow [0, 1]$  con  $\mathcal{N} = \{1, \dots, n\}$ , siendo  $n$  el número de clasificadores considerados. Recordamos que nuestro objetivo con esta medida es modelar las interacciones entre los clasificadores. Queremos reflejar el hecho de que un clasificador puede llegar a complementarse mejor con otro y, por lo tanto, llevarnos a una mejor solución. O, igualmente, que cuando se añade un nuevo clasificador, el desempeño del nuevo conjunto de clasificadores no incrementa como se esperaba. Dado que podemos estimar fácilmente como interaccionan los clasificadores evaluando cada posible subconjunto de clasificadores, proponemos utilizar su rendimiento para construir la medida difusa.

El proceso para establecer los valores de la medida difusa consiste en dos pasos. Primero, empezamos construyendo una medida difusa uniforme  $m_U : 2^{\mathcal{N}} \rightarrow [0, 1]$  la cual se calcula como  $m_U(A) = \frac{|A|}{n}$  para todo  $A \subseteq \mathcal{N}$ . Esta medida será la base para la medida objetivo. Luego, en el segundo paso consideraremos el rendimiento de cada clasificador individual así como el rendimiento de cada posible combinación de clasificadores, llamado  $Per_A$ , para todo  $A \subseteq \mathcal{N}$ . Ahora para cada subconjunto con la misma cardinalidad, calculamos la media aritmética de sus rendimientos. Por ejemplos, para todo subconjunto de clasificadores con cardinalidad  $i \in \{1, \dots, n\}$ , calculamos  $MeanPer_i$ . Finalmente, el valor de la medida difusa para cada  $A \subseteq \mathcal{N}$  será dado por:

$$m(A) = m_U(A) + \frac{\tanh(100 \cdot (Per_A - MeanPer_{|A|}))}{2n} \quad (3)$$

donde  $\tanh : (-\infty, +\infty) \rightarrow (-1, 1)$  es la función tangente hiporbólica dada por  $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ . *Nota:* Como los rendimientos son números reales en el intervalo unitario, multiplicamos estos por 100 para considerar el rendimiento como porcentaje.

Observar que el mapeo  $m$  dado en la Ecuación 3 satisface  $m(\emptyset) = 0$  y  $m(\mathcal{N}) = 1$ . Con respecto a la monotonía, es suficiente con ver que para todo  $i = 2, \dots, n-1$  y  $A \subset \mathcal{N}$  con  $|A| = i$ , tenemos que  $m(A) \in [(2i-1)/n, (2i+1)/n]$  y mantiene la monotonía. Analizando esta expresión, los rendimientos de los clasificadores que son mejores que el rendimiento medio en el mismo nivel serán incrementados y aquellos que son peores serán decrementados con respecto a la medida uniforme. Al igual que en el caso de la media ponderada, utilizamos como medida de rendimiento la GM.

Para comparar nuestra propuesta con métodos anteriores de medidas difusas y para mostrar las ventajas considerando todos los parámetros, utilizaremos las medidas difusas lambda [6], [7]. En este caso, solo tenemos que establecer el primer nivel de la medida difusa, dado que  $\lambda$  se obtiene de los valores de este nivel y posteriormente se puede derivar el resto de la medida difusa. El primer nivel de la medida difusa se obtiene de la misma forma que el método propuesto para reducir las diferencias entre su forma de trabajo.

#### V. ESTUDIO EXPERIMENTAL

En esta sección, primero explicaremos el marco experimental considerado para este estudio. Posteriormente, se prestan y se discuten los resultados experimentales.

##### V-A. Marco Experimental

Hemos considerado los treinta y tres conjuntos de datos mas desequilibrados (mayor ratio de no balanceo) del repositorio de datos de KEEL [12]. Hemos utilizado la validación cruzada con 5 particiones para obtener los resultados de cada método para cada conjunto de datos. Este esquema se repite 5 veces con diferentes semillas. Como medida de rendimiento utilizamos la GM (aunque se obtienen conclusiones similares cuando se considera la AUC). Además, hemos considerado el uso de test estadísticos no paramétricos [23] para analizar

adecuadamente los resultados obtenidos. Se ha utilizado el test de Friedman de rangos alineados para comparar un grupo de métodos con el objetivo de detectar diferencias significativas. En el caso de diferencias significativas, se aplica el test *post-hoc* de Holm para encontrar los algoritmos que rechazan la hipótesis nula de equivalencia frente al método de control seleccionado. Por otro lado, consideramos el test de Wilcoxon para estudiar si existen diferencias significativas entre dos métodos.

Siguiendo el análisis experimental desarrollado en trabajos anteriores, hemos considerado el árbol de decisión C4.5 [24] como clasificador base para nuestro ensemble (con pruning, nivel de confianza 0.25, mínimo número de ítems por hoja de 2 y confianza estimada mediante Laplace). Respeco al ensemble UnderBagging, hemos establecido el número de clasificadores a 10 para hacer posible la estimación de los valores de la medida difusa.

Para estudiar la ventaja de tener en cuenta la interacción entre clasificadores, compararemos el uso de diferentes funciones de agregación para la combinación de los clasificadores del ensemble. Realizaremos comparaciones intra- e inter-familiares con el objetivo de encontrar la mejor agregación. Todos los métodos considerados en el estudio se presentan en la Tabla I.

Tabla I  
MÉTODOS CONSIDERADOS EN LA COMPARACIÓN

Family	Abb.	Description
Unweighted	AM	Media Aritmética
	MED	Mediana
	GM	Media Geométrica
	HM	Media Armónica
Weighted	$AM_{gm}$	Media aritmética ponderada utilizando GM para el cálculo de los pesos
	$Q_{alh}$	OWA usando $Q_{alh}$ como función para el cálculo de los pesos
	$Q_{amap}$	OWA usando $Q_{amap}$ como función para el cálculo de los pesos
	$Q_{mot}$	OWA usando $Q_{mot}$ como función para el cálculo de los pesos
Choquet	$C_{gm}$	Choquet usando la métrica GM para el calculo de los pesos
	$C_{\lambda gm}$	Choquet usando medidas $\lambda$ y GM como métrica de rendimiento
Sugeno	$S_{gm}$	Sugeno usando la métrica GM para el calculo de los pesos
	$S_{\lambda gm}$	Sugeno usando medidas $\lambda$ y GM como métrica de rendimiento

## VI. RESULTADOS Y DISCUSIÓN

La Tabla II muestra los resultados obtenidos por cada método empleado (Tabla I) en términos de GM. Para cada conjunto de datos, se marca en **negrita** el mejor resultado. La última fila corresponde al rendimiento medio sobre todos los conjuntos de datos.

Atendiendo a la Tabla II, se puede observar que la función de agregación que obtiene mejor resultado medio es  $C_{gm}$ . Sin embargo,  $S_{gm}$  que usa la misma medida difusa no es capaz de conseguir el mismo rendimiento y obtiene una GM media menor que la media aritmética estándar. De todas formas, de estos números podemos concluir que las diferencias entre los diferentes métodos no son grandes en términos absolutos. No obstante, tenemos que estudiar estos resultados con el análisis estadístico adecuado.

Dado el número de métodos considerados en la comparación, hemos llevado a cabo un análisis estadístico jerárquico de los resultados, primero realizando comparación intra-familiares y posteriormente comparando los mejores métodos

Tabla II  
GM MEDIA OBTENIDA POR CADA MÉTODO EN CADA CONJUNTO DE DATOS

Dataset	Unweighted				Weighted				Choquet		Sugeno	
	AM	MED	GM	HM	$WAM_{gm}$	$Q_{alh}$	$Q_{amap}$	$Q_{mot}$	$C_{gm}$	$C_{\lambda gm}$	$S_{gm}$	$S_{\lambda gm}$
Glass04vs5	<b>0.9939</b>	<b>0.9939</b>	<b>0.9939</b>									
Ecol0346vs5	0.8822	0.8784	0.8423	0.7260	0.8845	0.8225	0.8446	0.8855	0.8881	<b>0.8890</b>	0.8875	0.8884
Ecol0347vs56	0.8659	0.8667	0.8060	0.7105	0.8666	0.8503	0.8126	0.8686	0.8737	0.8684	<b>0.8750</b>	0.8669
Yeast05679vs4	0.8112	0.8047	0.7837	0.6898	0.8088	0.7715	0.7695	0.8094	<b>0.8161</b>	0.8053	0.8070	0.8060
Ecol067vs5	0.8733	0.8726	0.8410	0.7239	0.8738	<b>0.8800</b>	0.8245	0.8731	0.8740	0.8738	0.8733	0.8718
Vowel0	0.9600	0.9604	0.9402	0.9196	0.9600	<b>0.9681</b>	0.9438	0.9589	0.9614	0.9619	0.9627	0.9624
Glass016vs2	0.6566	0.6490	0.5494	0.3449	0.6605	0.5436	0.5438	0.6555	<b>0.6611</b>	0.6381	0.6528	0.6511
Glass2	0.7140	0.7180	0.5692	0.3465	0.7143	0.5253	0.5555	0.7087	<b>0.7287</b>	0.7161	0.7225	0.7205
Ecol0147vs2356	0.8357	0.8365	0.7860	0.7002	0.8288	0.8235	0.7851	0.8262	0.8304	0.8354	0.8399	<b>0.8417</b>
Led7digit02456789vs1	0.8114	0.8150	0.7970	0.7879	0.8114	<b>0.8413</b>	0.7907	0.8081	0.8108	0.8195	0.8210	0.8210
Glass06vs5	0.9204	0.9183	0.9040	0.8581	0.9204	<b>0.9399</b>	0.9097	0.9130	0.9204	0.9324	0.9204	0.9345
Ecol01vs5	0.8726	0.8718	0.8185	0.7091	0.8710	0.8637	0.8452	0.8659	<b>0.8770</b>	0.8768	0.8755	0.8759
Glass0146vs2	0.7060	0.7011	0.5494	0.3607	0.7092	0.5493	0.5456	0.6890	<b>0.7227</b>	0.7207	0.7073	0.7070
Ecol0147vs56	0.8669	0.8630	0.7729	0.6510	0.8678	0.8637	0.7983	0.8563	0.8678	<b>0.8748</b>	0.8674	0.8722
Cleveland0vs4	0.8212	0.8085	0.6955	0.5763	0.8089	0.7249	0.7248	0.8152	<b>0.8268</b>	0.8174	0.8132	0.7522
Ecol0146vs5	0.8777	0.8778	0.8102	0.6963	0.8661	0.8549	0.8195	0.8803	<b>0.8893</b>	0.8776	0.8874	0.8755
Ecol4	0.8947	0.8943	0.8313	0.7345	0.8965	0.8975	0.8442	0.8906	0.8974	0.8965	0.8960	<b>0.8989</b>
Yeast1vs7	0.7498	0.7405	0.6366	0.5368	0.7470	0.6392	0.6128	0.7358	<b>0.7517</b>	0.7426	0.7508	0.7424
Shuttlecvs4	<b>1.0000</b>	<b>1.0000</b>	<b>1.0000</b>									
Glass4	<b>0.9171</b>	0.9040	0.8094	0.7062	0.9073	0.8731	0.8518	0.9052	0.9078	0.8985	0.9088	0.9096
Pageblocks13vs4	0.9731	0.9736	0.9095	0.8371	0.9785	<b>0.9881</b>	0.9327	0.9363	0.9790	0.9818	0.9797	0.9818
Abalone18	0.7512	<b>0.7539</b>	0.6847	0.5909	0.7534	0.6469	0.6668	0.7413	0.7522	0.7470	0.7467	0.7475
Ecol0147vs56	0.9411	0.9411	0.9411	0.9167	0.9411	<b>0.9441</b>	0.9411	0.9411	0.9411	0.9411	0.9411	0.9423
Shuttlecvs4	<b>1.0000</b>	<b>1.0000</b>	0.9812	0.9017	<b>1.0000</b>	0.9883	0.9930	<b>1.0000</b>	<b>1.0000</b>	0.9883	<b>1.0000</b>	<b>1.0000</b>
Glass06vs5	0.6132	0.6028	0.5034	0.4346	0.6171	0.4232	0.4265	0.5869	<b>0.6262</b>	0.6145	0.5932	0.6082
Glass5	0.9473	0.9473	0.9452	0.8880	0.9473	<b>0.9680</b>	0.9473	0.9473	0.9473	0.9554	0.9473	0.9590
Yeast1458vs7	0.7337	0.7301	0.6914	0.5726	0.7320	0.7382	0.7248	0.8152	<b>0.7998</b>	0.7255	0.7253	0.7303
Yeast4	0.8367	0.8345	0.8098	0.7818	0.8386	0.8262	0.8123	0.8338	<b>0.8455</b>	0.8427	0.8386	0.8398
Yeast1289vs7	0.7168	0.7071	0.6037	0.4960	0.7237	0.6260	0.5801	0.7073	<b>0.7275</b>	0.7153	0.7196	0.7104
Yeast5	0.9495	0.9504	0.9270	0.9044	0.9496	<b>0.9628</b>	0.9373	0.9526	0.9513	0.9513	0.9479	0.9487
Ecol0137vs26	0.7745	0.7724	0.6510	0.4892	<b>0.7762</b>	0.7561	0.7055	0.7504	0.7637	0.7371	0.7161	0.7093
Yeast6	0.8618	<b>0.8624</b>	0.8155	0.7471	0.8623	0.8521	0.8286	0.8566	0.8610	0.8602	0.8619	0.8622
Abalone19	0.6950	0.6902	0.6225	0.5792	0.6985	0.5827	0.6114	0.6850	<b>0.7076</b>	0.7063	0.6899	0.7007
Average	0.8432	0.8406	0.7825	0.6943	0.8429	0.8039	0.7842	0.8378	<b>0.8467</b>	0.8357	0.8415	0.8411

de cada familia. La Figura 1 representa este estudio. Cuando la comparación involucra solo dos métodos (familias Choquet y Sugeno), aplicamos el test de Wilcoxon, cuyos rangos se presentan cerca de cada método (a mayor el rango, mejor es el método). En otro caso, se utiliza el test de rangos alineados de Friedman para la comparación (a menor rango, mejor es el método). Además, marcamos en **negrita** los rangos cuando existen diferencias significativas con respecto al método ganador (con  $\alpha = 0,05$ ). Para ello, en el caso del test de Friedman, utilizamos el post-hoc test de Holm.

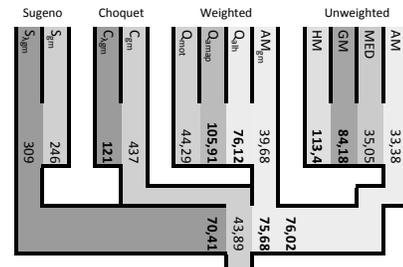


Figura 1. Estudio estadístico jerárquico comparando las funciones de fusión en cada familia y la mejor de cada familia

Entre las agregaciones no ponderadas, la media aritmética (AM) es la que mejor resultados obtiene seguida muy de cerca por la mediana (MED), mientras que la GM y la HM no proporcionan resultados competitivos. Respecto a las agregaciones ponderadas,  $AM_{gm}$  supera estadísticamente a todas excepto a un OWA ( $OWA_{mot}$ ), lo cual muestra la importancia de considerar la calidad de cada clasificador para realizar la agregación de los clasificadores en los ensembles basados en Bagging (con respecto a considerar únicamente la magnitud del voto para establecer el peso). Finalmente, las



agregaciones de Choquet y Sugeno presentan dos escenarios diferentes. Mientras que en Choquet, la medida propuesta se comporta mejor, en la familia Sugeno la medida lambda consigue un mejor rendimiento. No obstante, al enfrentar el mejor método de cada familia, el claro ganador es  $C_{gm}$ . La agregación Choquet con la medida propuesta, la cual sí tiene en cuenta la interacción entre los clasificadores, es capaz de superar al resto. De hecho, Choquet presenta un mejor resultado que la otra alternativa de integral difusa.

Finalmente, para completar nuestro estudio experimental, hemos comparado directamente el mejor método de cada familia frente a la AM, ya que es la agregación más comúnmente considerada para combinar clasificadores. Estas comparaciones se han realizado utilizando el test de Wilcoxon y se presentan en la Tabla III. Por cada comparación se presentan los rangos a favor de cada método, el p-valor y si la hipótesis nula de equivalencia es rechazada o no.

Tabla III

TEST DE WILCOXON COMPARANDO LA AM CONTRA LA MEJOR FUNCIÓN DE FUSIÓN DE CADA FAMILIA

Comparación	R <sup>+</sup>	R <sup>-</sup>	Hipótesis ( $\alpha = 0,05$ )	p-value
AM vs. AM <sub>gm</sub>	214	311	No rechazada	0.2348
AM vs. C <sub>gm</sub>	89	451	Rechazada para C <sub>gm</sub>	0.0006
AM vs. S <sub>λgm</sub>	252	303	No rechazada	0.6106

En esta tabla se puede observar que  $C_{gm}$  es la única agregación capaz de superar estadísticamente a la AM. Es más, este resultado es interesante ya que muestran que el uso de la AM puede ser mejorado con la función de agregación adecuada.

## VII. CONCLUSIONES

En este trabajo hemos presentado una nueva forma para aprender una medida difusa a partir del rendimiento de los clasificadores con el objetivo de mejorar la fase de agregación de los ensembles. Hemos realizado un estudio experimental completo comparando nuestra propuesta con diferentes familias de funciones de agregación y también con el uso de las medidas difusas lambda consideradas en la literatura. En el marco experimental considerado, los experimentos han presentado que la medida propuesta junto a la integral de Choquet mejora significativamente el uso de la comúnmente utilizada media aritmética.

En el futuro nuestro objetivo es estudiar cómo abordar la mayor desventaja del uso de las medidas difusas, el hecho de que hay que estimar  $2^N$  parámetros (siendo  $N$  el número de entradas a agregar). Además, nuestro propósito es mejorar el marco experimental añadiendo mas conjuntos de datos y otros escenarios diferentes al del problema de las clases no balanceados. También compararemos el método propuesto con otros métodos para la agregación de clasificadores que no están directamente basados en el uso de funciones de agregación.

## AGRADECIMIENTOS

Este trabajo ha sido apoyado en parte por el Ministerio Español de Ciencia y Tecnología bajo el Proyecto TIN2016-77356-P (AEI/FEDER, UE).

## REFERENCIAS

- [1] L. I. Kuncheva, *Combining Pattern Classifiers: Methods and Algorithms*. Wiley-Interscience, 2004.
- [2] L. Breiman, "Bagging predictors," *Machine Learning*, vol. 24, pp. 123–140, 1996.
- [3] Y. Freund and R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of Computer and System Sciences*, vol. 55, no. 1, pp. 119–139, 1997.
- [4] J.-L. Marichal, "On choquet and sugeno integrals as aggregation functions," in *Fuzzy Measures and Integrals. Theory and Applications*, T. M. M. Grabisch and M. Sugeno, Eds. Physica-Verlag, 2000, pp. 247–272.
- [5] —, "Aggregation of interacting criteria by means of the discrete choquet integral," in *Aggregation Operators. New Trends and Applications*, T. Calvo, G. Mayor, and R. Mesiar, Eds. Physica-Verlag, 2002, pp. 224–244.
- [6] S.-B. Cho and J. H. Kim, "Multiple network fusion using fuzzy logic," *IEEE Transactions on Neural Networks*, vol. 6, no. 2, pp. 497–501, 1995.
- [7] L. I. Kuncheva, "'fuzzy' versus 'nonfuzzy' in combining classifiers designed by boosting," *IEEE Transactions on Fuzzy Systems*, vol. 11, no. 6, pp. 729–741, 2003.
- [8] G. Choquet, "Theory of capacities," *Ann. Inst. Fourier*, vol. 5, pp. 1953–1954, 1953.
- [9] M. Sugeno, "Theory of fuzzy integrals and its applications," Ph.D. dissertation, Tokyo Institute of Technology, 1974.
- [10] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, and F. Herrera, "A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches," *IEEE Transactions on Systems, Man, and Cybernetics—Part C: Applications and Reviews*, vol. 42, no. 4, pp. 463–484, 2012.
- [11] R. Barandela, R. M. Valdovinos, and J. S. Sánchez, "New applications of ensembles of classifiers," *Pattern Analysis & Applications*, vol. 6, pp. 245–256, 2003.
- [12] J. Alcalá-Fdez, A. Fernandez, J. Luengo, J. Derrac, S. García, L. Sánchez, and F. Herrera, "KEEL data-mining software tool: Data set repository, integration of algorithms and experimental analysis framework," *Journal of Multiple-Valued Logic and Soft Computing*, vol. 17:2-3, pp. 255–287, 2011.
- [13] T. Calvo, G. Mayor, and R. Mesiar, *Aggregation Operators. New Trends and Applications*. Physica-Verlag, 2002.
- [14] G. Beliakov, A. Pradera, and T. Calvo, *Aggregation Functions: A Guide for Practitioners*. Springer, 2007.
- [15] M. Grabisch, J.-L. Marichal, R. Mesiar, and E. Pap, *Aggregation Functions*. Cambridge University Press, 2009.
- [16] G. Beliakov, H. Bustince, and A. Pradera, *A Practical Guide to Averaging Functions*, 2nd ed. Springer, 2015.
- [17] H. Bustince, J. Fernandez, A. Kolesárová, and R. Mesiar, "Directional monotonicity of fusion functions," *European Journal of Operational Research*, vol. 244, pp. 300–308, 2015.
- [18] D. Paternain, M. Campión, H. Bustince, I. Perfilieva, and R. Mesiar, "Internal fusion functions," *IEEE Transactions on Fuzzy Systems*, InPress.
- [19] Y. Narukawa and V. Torra, "Fuzzy measure and probability distributions: distorted probabilities," *IEEE Transactions on Fuzzy Systems*, vol. 13, pp. 617–629, 2005.
- [20] H. He and E. A. Garcia, "Learning from imbalanced data," *IEEE Transactions on Knowledge and Data Engineering*, vol. 21, no. 9, pp. 1263–1284, 2009.
- [21] R. Barandela, J. S. Sánchez, V. García, and E. Rangel, "Strategies for learning in class imbalance problems," *Pattern Recognition*, vol. 36, no. 3, pp. 849–851, 2003.
- [22] R. Yager, "Quantifier guided aggregation using owa operators," *International Journal of Intelligent Systems*, vol. 11, pp. 49–73, 1998.
- [23] S. García, A. Fernández, J. Luengo, and F. Herrera, "Advanced non-parametric tests for multiple comparisons in the design of experiments in computational intelligence and data mining: Experimental analysis of power," *Information Sciences*, vol. 180, pp. 2044–2064, 2010.
- [24] J. R. Quinlan, *C4.5: Programs for Machine Learning*, 1st ed. San Mateo-California: Morgan Kaufmann Publishers, 1993.

# Using Ensembles for Improving Fall Detection

1<sup>st</sup> José R. Villar  
*Computer Science Department*  
*University of Oviedo*  
Oviedo, Spain  
villarjose@uniovi.es

2<sup>nd</sup> Enrique de la Cal  
*Computer Science Department*  
*University of Oviedo*  
Oviedo, Spain  
delacal@uniovi.es

3<sup>rd</sup> Víctor M. González  
*Electrical Engineering Department*  
*University of Oviedo*  
Gijón, Spain  
vmsuarez@uniovi.es

4<sup>th</sup> Javier Sedano  
*Applied Electronics and Artificial Intelligence Group*  
*Instituto Tecnológico de Castilla y León*  
Burgos, Spain  
javier.sedano@itcl.es

**Abstract**—Technology can highly enhance the quality of life of elderly people when living autonomously. Actually, fall detection is one of the possible improvements: having an oracle to request help in case of falling may succeed in providing confidence to adults who have already fallen, for instance. In a recent study, a wrist worn wearable solution has been proposed based on threshold for peak detection and several low computational models for classifying the peak events as related with falls. It was found that ensembles could lead to a better performance of the system. In this research, a preliminary study in ensembling the classifiers is proposed, analysing the outcome in each case for each of the different scenarios initially proposed. Although a very simple ensemble solution is used, results suggest this may be the solution when a robust fall detection system is needed.

**Index Terms**—Fall Detection, Neural Networks, Support Vector Machines, Ensemble of Classifiers

## I. INTRODUCTION

Fall Detection (FD) is a very active research area, with many applications in health care, work safety, etc. [1]. Even though there are plenty of commercial products, the best rated products only reach 80% of success [2]. There are basically two types of FD systems: context-aware systems and wearable devices [3], [4]. FD has been widely studied using context-aware systems, i.e. video systems [5]; nevertheless, the use of wearable devices is crucial because of the high percentage of elderly people and their desire to live autonomously at their own house [6].

By far, tri-axial accelerometry (3DACC) is the most used option within the literature of FD [7]–[11]. Different solutions have been proposed to perform the FD, for instance, a feature extraction stage and SVM have been applied directly in [7], [9], using some transformations and thresholds with very simple rules for classifying an event as a fall [10]–[12]. A comparison of classifiers has been presented in [8].

As stated in [13], the most common location of the 3DACC sensor is on the waist. This location has been proven valid for FD when the subject suffers from a impairment disease;

however, it might not be the best option when focusing on autonomous population. It is suggested that, for this sort of people, a wrist-based solution would suit better. Furthermore, in [13], an improvement of a FD method has been proposed using a 3DACC wearable device placed on a wrist. Although good results were given, the solution needs further improvements to reduce the false alarms or the undetected events. One of the possible solutions is to use an ensemble of classifiers using those models that performed the best. In this study, a very simple combination of these methods is proposed, analysing the outcome of the ensemble of the methods.

Next section deals with the description of the FD system and the details of the model ensemble. Section III deals with the datasets and the evaluation of the hypothesis. Section IV shows and discusses the obtained results. Finally, conclusions are drawn.

## II. FALL DETECTION WITH WRIST-WORN WEARABLES

The method was originally proposed in [14], being extended in [13]. Basically, it is a threshold-based peak detection stage followed by feature extraction and classification stages. Several different models were proposed. In this study we suggest ensembling them to improve the FD.

In the next subsection, the peak detection and feature extraction stages are detailed, while in subsection II-B the different models and the ensemble of the outcome are described.

### A. Peak detection and feature extraction

As proposed in [13], [14], a very simple finite state machine is used to detect the falls; this state machine is shown in Figure 1. The data gathered from a 3DACC located on the wrist is processed using a sliding window. A peak detection is performed, and if a peak is found, the data within the sliding window is analysed to extract several features which are ultimately classified as FALL or NOT\_FALL. The FD block is performed with a classifier. In [15] it was claimed that the lower the computational cost of the classifier the better as it must be run in the wearable device.

This research has been funded by the Spanish Ministry of Science and Innovation, under projects MINECO-TIN2014-56967-R and MINECO-TIN2017-84804-R.

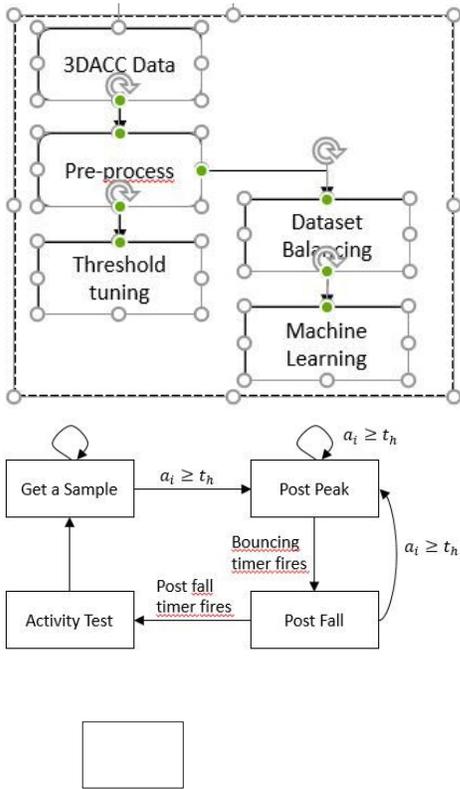


Fig. 1: Block diagram of the solution. Upper part: both the threshold and the classifier are trained using a dataset. Center part: the finite state machine, the bouncing and post fall timers are set to 1000 and 1500 ms, respectively. Bottom part: the features are computed and the extracted sample is classified whenever a peak is detected.

The feature extraction is executed whenever a peak is detected and follows the dynamics within a fall -refer to Fig. 2-. Let us assume that gravity be  $g = 9.8m/s$ . Given the current timestamp  $t$ , we find a peak at **peak time**  $pt = t - 2500ms$  (point 1) if at time  $pt$  the magnitude of the acceleration  $a_t$  -see Equation 1- is higher than  $th_1 = 3 \times g$  and there is no other peak in the period  $(t - 2500ms, t]$  (no other  $a$  value higher than  $th_1$ ). If this condition holds, then it is stated that a peak occurred at  $pt$ .

$$a_t = \sqrt{a_{tx}^2 + a_{ty}^2 + a_{tz}^2} \quad (1)$$

The **impact end** ( $ie$ ) (point 2) denotes the end of the fall event; it is the last time for which the  $a$  value is higher than  $th_2 = 1.5 \times g$ . Finally, the **impact start** ( $is$ ) (point 3) denotes the starting time of the fall event, computed as the time of the first sequence of an  $a \leq th_3$  ( $th_3 = 0.8 \times g$ ) followed by a value of  $a \geq th_2$ . The impact start must belong to the interval  $[ie - 1200 ms, pt]$ . If no impact end is found, then it

is fixed to  $pt + 1000$  ms. If no impact start is found, it is fixed to  $pt$ . From now on and without losing generalization, as long as we know the sampling frequency, we can refer to timestamp or to positions within a sliding window that includes the samples in  $[is, ie]$ .

When using subindex  $i$  we refer to the sample position within the sliding window, and when using subindex  $t$  we refer to a timestamp; however, they are interchangeable. When a peak is detected the feature extraction is performed, computing for this peak time several parameters and features.

With these three times  $-is, pt, ie-$  calculated, the following transformations should be computed:

- Average Absolute Acceleration Magnitude Variation,  $AAMV = \sum_{t=is}^{ie} \frac{|a_{t+1} - a_t|}{N}$ , with  $N$  the number of samples in the interval.
- Impact Duration Index,  $IDI = ie - is$ .
- Maximum Peak Index,  $MPI = \max_{t \in [is, ie]}(a_t)$ .
- Minimum Valley Index,  $MVI = \min_{t \in [is - 500, ie]}(a_t)$ .
- Peak Duration Index,  $PDI = pe - ps$ , with  $ps$  the peak start defined as the time of the last magnitude sample below  $th_{PDI} = 1.8 \times g$  occurred before  $pt$ , and  $pe$ , the peak end defined as the time of the first magnitude sample below  $th_{PDI} = 1.8 \times g$  occurred after  $pt$ .
- Activity Ratio Index,  $ARI$ , calculated as the ratio between the number of samples not in  $[th_{ARIlow} 0.85 \times g, th_{ARIhigh} = 1.3 \times g]$  and the total number of samples in the 700 ms interval centered in  $(is + ie)/2$ .
- Free Fall Index,  $FFI$ , the average magnitude in the interval  $[t_{FFI}, pt]$ . The value of  $t_{FFI}$  is the time between the first acceleration magnitude below  $th_{FFI} = 0.8 \times g$  occurring up to 200 ms before  $pt$ ; if not found, it is set to  $pt - 200 ms$ .
- Step Count Index,  $SCI$ , measured as the number of peaks in the interval  $[pt - 2200, pt]$ .

As stated in the Introduction section of this study, several solutions for FD are based on threshold to detect peaks plus an extra processing [10], [16]–[18]. The solution proposed in [14] is not different. Furthermore, several thresholds are used in that study not only to detect a peak but also to compute the extracted features. All of them have been fixed by analysing the gathered data, establishing some typical values for the features for the class FALL. In order to obtain a better threshold, [13] proposed the use of computational intelligence and optimization, suggesting that Genetic Algorithms and Simulated Annealing would find most suitable values for the threshold.

### B. Ensemble of models

According to the block diagram, each sample of these eight features is classified as a fall event or not using the predefined model. Therefore, this model has to be trained; this topic is covered in the next subsection.

As explained in [13], several different low computational models were proposed to classify each peak as Fall or Not\_Fall; the constraint of reduced computational capacity is a current limit in nowadays wearable devices. Therefore,

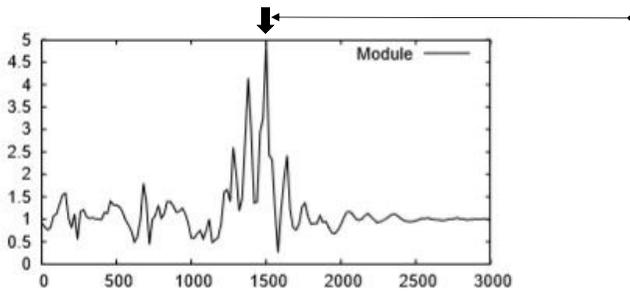


Fig. 2: Graph elaborated from [14], showing the evolution of the magnitude of the acceleration in multiples of  $g$ . Analysing the signal at time stamp  $t$ , the peak condition described in the text must be found in order to detect a fall. The x-axis represents the time; each mark corresponds to 500 ms.

Decision Trees (DT) using C5.0, Rule Based Systems (RBS) also using C5.0, and Support Vector Machines (SVM) were added to the original option of feed-forward Neural Networks (NN).

Provided there exists a collection of Time Series (TS) with data gathered from real falls or from Activities of Daily Living (ADL), a training phase can be proposed to train the FD model. Let us consider a dataset containing  $\{TS_i^L\}$ , with  $i = 1 \dots N$ , where  $n$  is the number of TS samples and  $L$  is the assigned label; that is, a sample of this dataset is a  $TS_i^L$  with the data gathered from a participant using a 3DACC on the chosen location, i.e., on a wrist. Let us assume we know a priori whether this  $TS_i^L$  includes or not the signal gathered when a fall occurred; therefore, each TS is labelled as  $L = FALL$  or  $L = NOT\_FALL$ .

Now, let us evaluate the peak detection and the feature extraction blocks for each TS. Whenever a  $TS_i^L$  has no peak, the  $TS_i^L$  is discarded. When a peak is detected for  $TS_i^L$ , then the eight features are computed, and label  $L$  can be assigned to this new sample. Therefore, a new dataset is created with  $M$  eight features labelled samples, with  $M \leq N$ . This dataset was used in [14] to train the feed-forward NN.

Nevertheless, it has been found that this solution i) might generate more than a sample for a single  $TS_i^L$  -which is not a problem-, and ii) certainly will generate a very biased dataset, with the majority of the samples belonging to the class FALL. From their study [14], it can be easily drawn that the main reason of a 100% of detection is this biased dataset.

Consequently, in this research we propose to include a dataset balancing stage using SMOTE [19], so at least a 40/60 ratio is obtained for the minority class.

Therefore, in this study we discard the method of DT because it was the one that was found with higher number of undetected events and higher number of false alarms. The remaining three models (RBS, SVM and NN) will be used as independent classifiers; the ensemble is computed as the weighted sum of the outcomes of the three models, using the same weight for each one. As mentioned before, this is a preliminary study and just a simple solution is fetched in

order to evaluate whether the outcome of the system can be enhanced or not.

### III. MATERIAL AND METHODS

#### A. Public Datasets

A common way of studying FD is by developing a dataset of simulated falls plus extra sessions of different ADL. All these TS are labelled and become the test set for the corresponding study. The vast majority of these datasets were gathered with the sensor attached to the main body -either on the chest, waist, lumbar area, or thigh-.

In this research, three publicly available 3DACC datasets are used:

- UMA Fall dataset [20] includes data gathered from 3DACC sensors placed on different parts of the body - ankle, waist, wrist and, head- while performing simulated falls; this is the type of data needed in this research because the main hypothesis of this study is to perform FD with a sensor worn on a wrist. Furthermore, there is no pattern in the number of repetitions of each activity or fall simulation. Some participants did not simulate any fall, some performed 6 or 9, and one participant simulated 60 falls.
- UNIOVI dataset [21] includes ADL and simulated epileptic seizures [22]. This one has been considered because it includes a high movement activity -the simulated partial tonic-clonic seizures- followed by a relatively calm period plus some other ADL, all of them measured using 3DACC placed on the dominant wrist.
- DaLiaC dataset [23] includes several sensors, one on the wrist and one on the waist among others. Up to 19 young healthy participants and up to 13 different ADL are considered, from sitting to cycling.

#### B. The Experimentation Scheme

As proposed in [13], a participant based cross validation (cv) scheme is performed, including training, testing and validation. Once a participant is chosen for validation -or train and test-, all the TS gathered for that participant are included in the validation -or train and test- dataset. The 15% of the participants from the UMA Fall and the UNIOVI datasets have been chosen for validation, the remaining participants are assigned to the training and testing dataset.

The general process is depicted in Fig. 3. The training and testing dataset was used in [13] for tuning the threshold to perform the peak detection; three thresholds were considered: 2.5 as the minimum value of a peak for the 3DACC magnitude, 3.0 given in [14] and 3.09590 obtained from the optimization stage.

The peak detection algorithm is run on the TS belonging to the train and test dataset; for each peak detected, the features are extracted and labelled as FALL or NOT\_FALL. This procedure produces a feature extraction dataset; this dataset is used to train the models using either 5x2 cv or 10-fold cv. In this research, 5x2 cv has been used. Because this dataset might be highly imbalanced, SMOTE is applied to obtain a more



Fig. 3: The Machine Learning process within the cross validation scheme. The training and testing dataset is used for i) threshold optimization, and ii) peak detection and feature extraction. The labelled dataset is then used for the machine learning process to find the best modelling option. The best option is then evaluated with the validation dataset once processed so the real performance of the system can be obtained.

suitable dataset to use in the learning process; the balanced dataset must have a minority class percentage within 40%-60%. Afterwards, the models are learnt using grid search for the best parameter subset.

Finally, the validation dataset is considered. It goes through the peak detection block -using the optimized threshold- and, whenever a peak is found, the feature extraction stage is executed. Finally, the eight features are classified using the best model found in the previous stage. A TS from the validation dataset will be classified as FALL if a peak is detected and the subsequent classifier outputs the FALL label; otherwise, the TS will be assigned the label NO\_FALL.

In this study, the same participant based cv and the same models used in [13] are proposed. Only the validation is performed differently. This is because the hypothesis is that using ensembles of the models obtained in the train and test stage can improve the overall performance of the FD system. Therefore, only the validation stage is performed, comparing the results of each individual model with the very simple ensemble scheme detailed before.

#### IV. EXPERIMENTATION'S RESULTS

##### A. Obtained Results

Table I and Table II show the results obtained in the validation; the former includes the confusion matrices, while the latter shows the standard statistical measurements. Although the number of TS belonging to the Fall class are relatively too small, it seems that the ensemble obtained performance is nearly as good as the best model in terms of the number of detected events, while at the same time reduces the number of false alarms. Still, some undetected fall events can be observed, though.

TABLE I: Confusion matrices for the three analysed thresholds and for each model type: feed-forward NN, rule base systems learned with C5.0 (RBS) and, Support Vector Machines (SVM). ENS stands for ensembling the outcome of the models.

Threshold 2.5					
Reference			Reference		
NN	Fall	Not Fall	RBS	Fall	Not Fall
Fall	10	47	Fall	10	42
Not Fall	2	250	Not Fall	2	245
SVM	Fall	Not Fall	ENS	Fall	Not Fall
Fall	8	18	Fall	10	37
Not Fall	4	279	Not Fall	2	260
Threshold 3.0					
Reference			Reference		
NN	Fall	Not Fall	RBS	Fall	Not Fall
Fall	12	52	Fall	11	29
Not Fall	0	245	Not Fall	1	268
SVM	Fall	Not Fall	ENS	Fall	Not Fall
Fall	10	12	Fall	11	29
Not Fall	2	285	Not Fall	1	268
Threshold 3.09290					
Reference			Reference		
NN	Fall	Not Fall	RBS	Fall	Not Fall
Fall	12	59	Fall	12	35
Not Fall	0	238	Not Fall	0	262
SVM	Fall	Not Fall	ENS	Fall	Not Fall
Fall	10	13	Fall	12	31
Not Fall	2	284	Not Fall	0	266

##### B. Discussion

Clearly, the number of TS in the validation dataset were not enough to gather a proper conclusion. It is simply too small to evaluate the general performance. Therefore, the first issue to solve is the number of TS. In a recent study [24], up to twelve publicly available datasets related with FD and ADL were compared. However, these datasets show as a very sparse effort, with different ADLs, goals, population, etc. besides, the UNIOVI dataset [21] also includes ADLs. Moreover, each of published datasets includes its own set of 3DACC sensors, placed on different body locations. Some of them include only data from the waist, others include data from different places.

In the context of this research, where the wearable device is expected to be on one wrist, only five datasets are valid for further work. Nevertheless, the Gravity Project dataset [25], which made use of a smartphone and an Android wearable, does not include the TS from the on wrist sensor, only from the smartphone. Therefore, the four datasets depicted in the next item list can be used in future work for a total of 1414 TS, of which 412 include simulated falls using different sensors and sampling frequencies with different behaviour performed by up to 55 participants. Each TS will be assigned either a FALL or NOT\_FALL label, accordingly to the TS including a fall or not.

On the other hand, the presented ensembling method is one of the most simple ensembling scheme. Several improvements can be performed on this topic. Firstly, the weights can be easily fixed taking advantage of the statistical measurements of performance of the models: the better the model is, the higher the relative weight. Or the vote, because the voting scheme can also be introduced in this context.

TABLE II: Results obtained for the best model for each threshold. Different statistics are shown: the Accuracy (Acc), Kappa factor (Kp), Sensitivity (Se), Specificity (Sp), Precision or positive predictive value (Pr) and the geometric mean of Sp and Se (G). The models are feed-forward NN, rule base systems learned with C5.0 (RBS), and Support Vector Machines (SVM). ENS stands for the ensemble of the different models.

Threshold	Model	Acc	Kp	Se
2.5	NN	0.8414	0.2412	<b>0.8333</b>
	DT	<b>0.9288</b>	<b>0.4454</b>	<b>0.8333</b>
	RBS	0.8576	0.2662	<b>0.8333</b>
	SVM	<b>0.9288</b>	0.3886	0.6667
	ENS	0.8738	0.2954	<b>0.8333</b>
3.0	NN	0.8317	0.2679	<b>1.0000</b>
	DT	0.9385	0.5096	0.9167
	RBS	0.9029	0.3864	0.9167
	SVM	<b>0.9547</b>	<b>0.5664</b>	0.8333
	ENS	0.9029	0.3864	0.9167
3.09290	NN	0.8091	0.2386	<b>1.0000</b>
	DT	0.9126	0.4146	0.9167
	RBS	0.8867	0.3677	<b>1.0000</b>
	SVM	<b>0.9515</b>	<b>0.5484</b>	0.8333
	ENS	0.8997	0.3999	<b>1.0000</b>

Threshold	Model	Sp	Pr	G
2.5	NN	0.8418	0.1754	0.8375
	DT	0.9327	<b>0.3333</b>	<b>0.8816</b>
	RBS	0.8586	0.1923	0.8459
	SVM	<b>0.9394</b>	0.3077	0.7914
	ENS	0.8754	0.2128	0.8541
3.0	NN	0.8249	0.1875	<b>0.9082</b>
	DT	0.9394	0.3793	<b>0.9280</b>
	RBS	0.9024	0.2750	0.9095
	SVM	<b>0.9596</b>	<b>0.4545</b>	0.8942
	ENS	0.9024	0.2750	0.9095
3.09290	NN	0.8013	0.1690	0.8952
	DT	0.9125	0.2973	0.9146
	RBS	0.8822	0.2553	0.9392
	SVM	<b>0.9562</b>	<b>0.4348</b>	0.8927
	ENS	0.8956	0.2791	<b>0.9464</b>

Furthermore, what is really important is to introduce a new testing scenario. With all these available TS, and even considering the participant cross validation -which we do think is important-, there is enough size to have a proper training, test and validation datasets. For instance, the train dataset can be used as described in this paper to obtain the models in the feature extraction domain; the test dataset can be used in determining the best ensemble scenario, while the validation dataset would keep the same aim as in this research. It seems this experimentation might allow us to obtain a suitable FD system for this type of falls.

## V. CONCLUSIONS

In this research a fall detection method has been described using a wearable device placed on a wrist measuring tri-axial accelerometry; this method is based on thresholds. The basic idea is to detect peaks of high activity; for those peaks a feature extraction stage is performed. Using publicly available datasets, a train, test and validation experimentation has been

designed; the train and test stage allows to obtain models, while the validation stage mimics the performance of the system with unseen participants.

In order to reduce the number of false alarms while keeping the accuracy high, this study has proposed using ensembles. It has been found that this idea seems to perform better: not only a higher accuracy is obtained but also the number of false alarms is reduced.

Moreover, several possibilities of how to enhance these results have been discussed. On the one hand, making use of more datasets with a proper selection of data sources. On the second hand, different schemes of ensembling can be easily introduced. Besides, provided new collections of data are available, better solutions for the training, testing and validation stages have been introduced.

Finally, all these arrangements needs to be addressed, but also a careful analysis of the data gathered from the focused population is needed. As it is known, the level of activity decreases with the age, and so does the possible scenarios of a fall event. This issue must be studied using, if possible, data gathered from the target population.

## REFERENCES

- [1] L. Rubenstein, "Falls in older people: epidemiology, risk factors and strategies for prevention," *Age Ageing*, vol. 35, pp. 37–41, 2006.
- [2] F. Bagala, C. Becker, A. Cappello, L. Chiari, K. Aminian, J. M. Hausdorff, W. Zijlstra, and J. Klenk, "Evaluation of accelerometer-based fall detection algorithms on real-world falls," *PLoS ONE*, vol. 7, no. 5, p. e37062, 2012.
- [3] R. Igual, C. Medrano, and I. Plaza, "Challenges, issues and trends in fall detection systems," *BioMedical Engineering OnLine*, vol. 12, no. 66, 2013. [Online]. Available: <http://www.biomedical-engineering-online.com/content/12/1/66>
- [4] S. S. Khan and JesseHoe, "Review of fall detection techniques: A data availability perspective," *Medical Engineering and Physics*, vol. 39, pp. 12–22, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1350453316302600>
- [5] S. Zhang, Z. Wei, J. Nie, L. Huang, S. Wang, , and Z. Li, "A review on human activity recognition using vision-based method," *Journal of Healthcare Engineering*, vol. 2017, Article ID 3090343, p. 31 pages, 2017.
- [6] P. Kumari, L. Mathew, and P. Syal, "Increasing trend of wearables and multimodal interface for human activity monitoring: A review," *Biosensors and Bioelectronics*, vol. 90, no. 15, pp. 298–307, April 2017.
- [7] T. Zhang, J. Wang, L. Xu, and P. Liu, "Fall detection by wearable sensor and one-class svm algorithm," in *Intelligent Computing in Signal Processing and Pattern Recognition*, ser. Lecture Notes in Control and Information Systems, I. G. Huang DS., Li K., Ed. Springer Berlin Heidelberg, 2006, vol. 345, pp. 858–863.
- [8] A. Hakim, M. S. Huq, S. Shanta, and B. Ibrahim, "Smartphone based data mining for fall detection: Analysis and design," *Procedia Computer Science*, vol. 105, pp. 46–51, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877050917302065>
- [9] F. Wu, H. Zhao, Y. Zhao, and H. Zhong, "Development of a wearable-sensor-based fall detection system," *International Journal of Telemedicine and Applications*, vol. 2016, Article ID 576364, no. 1, p. 11 pages, 2015. [Online]. Available: <https://www.hindawi.com/journals/ijta/2015/576364/>
- [10] A. Bourke, J. O'Brien, and G. Lyons, "Evaluation of a threshold-based triaxial accelerometer fall detection algorithm," *Gait and Posture*, vol. 26, pp. 194–199, 2007.
- [11] Q. T. Huynh, U. D. Nguyen, L. B. Irazabal, N. Ghassemian, and B. Q. Tran, "Optimization of an accelerometer and gyroscope-based fall detection algorithm," *Journal of Sensors*, vol. 2015, Article ID 452078, no. 452078, p. 8 pages, 2015.



- [12] M. Kangas, A. Konttila, P. Lindgren, I. Winblad, and T. Jämsä, "Comparison of low-complexity fall detection algorithms for body attached accelerometers," *Gait and Posture*, vol. 28, pp. 285–291, 2008.
- [13] S. B. Khojasteh, J. R. Villar, C. Chira, V. M. González, and E. de la Cal, "Improving fall detection using an on-wrist wearable accelerometer," *Sensors*, vol. 18, no. 5, 2018.
- [14] S. Abbate, M. Avvenuti, F. Bonatesta, G. Cola, P. Corsini, and AlessioVecchio, "A smartphone-based fall detection system," *Pervasive and Mobile Computing*, vol. 8, no. 6, pp. 883–899, December 2012.
- [15] S. B. Khojasteh, J. R. Villar, C. Chira, V. M. González, and E. de la Cal, "Improving fall detection using an on-wrist wearable accelerometer," *Sensors*, vol. accepted for publication, pp. 1–20, 2018.
- [16] A. Bourke, P. van de Ven, M. Gamble, R. O'Connor, K. Murphy, E. Bogan, E. McQuade, P. Finucane, G. O'laighin, and J. Nelson, "Evaluation of waist-mounted tri-axial accelerometer based fall-detection algorithms during scripted and continuous unscripted activities," *Journal of Biomechanics*, vol. 43, pp. 3051–3057, 2010.
- [17] A. K. Bourke, J. Klenk, L. Schwickert, K. Aminian, E. A. F. Ihlen, S. Mellone, J. L. Helbostad, L. Chiari, and C. Becker, "Fall detection algorithms for real-world falls harvested from lumbar sensors in the elderly population: A machine learning approach," in *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2016, pp. 3712–3715.
- [18] S. Abbate, M. Avvenuti, P. Corsini, J. Light, and A. Vecchio, *Wireless Sensor Networks: Application - Centric Design*. Intech, 2010, ch. Monitoring of human movements for fall detection and activities recognition in elderly care using wireless sensor network: a survey, p. 22.
- [19] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "Smote: synthetic minority over-sampling technique," *Journal of artificial intelligence research*, vol. 16, pp. 321–357, 2002.
- [20] E. Casilari, J. A. Santoyo-Ramón, and J. M. Cano-García, "Umafall: A multisensor dataset for the research on automatic fall detection," *Procedia Computer Science*, vol. 110, no. Supplement C, pp. 32 – 39, 2017, 14th International Conference on Mobile Systems and Pervasive Computing (MobiSPC 2017) / 12th International Conference on Future Networks and Communications (FNC 2017) / Affiliated Workshops. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877050917312899>
- [21] J. R. Villar, P. Vergara, M. Menéndez, E. de la Cal, V. M. González, and J. Sedano, "Generalized models for the classification of abnormal movements in daily life and its applicability to epilepsy convulsion recognition," *International Journal of Neural Systems*, vol. 26, no. 1650037, 2016.
- [22] J. R. Villar, "Author web page, public resources." [http://www.di.uniovi.es/~villar/Jose\\_R.\\_Villar/Public\\_Data\\_sets/Public\\_Data\\_sets.html](http://www.di.uniovi.es/~villar/Jose_R._Villar/Public_Data_sets/Public_Data_sets.html), 2016, last checked 16-11-2016.
- [23] H. Leutheuser, D. Schuldhaus, and B. M. Eskofier, "Hierarchical, multi-sensor based classification of daily life activities: comparison with state-of-the-art algorithms using a benchmark dataset," *PLoS ONE*, vol. 8, no. 75196, 2013.
- [24] E. Casilari, J.-A. Santoyo-Ramón, and J.-M. Cano-García, "Analysis of public datasets for wearable fall detection systems," *Sensors*, vol. 17, no. 1513, pp. 4324 – 4338, 2017. [Online]. Available: <http://www.mdpi.com/1424-8220/17/7/1513>
- [25] T. Vilarinho, B. Farshchian, D. G. Bajer, O. H. Dahl, I. Egge, S. S. Hegdal, A. Lønes, J. N. Slettevold, and S. M. Weggensen, "A combined smartphone and smartwatch fall detection system," in *2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing*, Oct 2015, pp. 1443–1448.

# NMC: Nearest Matrix Classification – A new combination model for pruning One-vs-One ensembles by transforming the aggregation problem

Mikel Galar

*Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, España  
mikel.galar@unavarra.es

Alberto Fernández

*Ciencias de la Computación e Inteligencia Artificial, Universidad de Granada*  
Granada, España  
alberto@decsai.ugr.es

Eduarne Barrenechea

*Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, España  
edurne.barrenechea@unavarra.es

Humberto Bustince

*Estadística, Informática y Matemáticas*  
*Universidad Pública de Navarra*  
Pamplona, España  
bustince@unavarra.es

Francisco Herrera

*Ciencias de la Computación e Inteligencia Artificial, Universidad de Granada*  
Granada, España  
herrera@decsai.ugr.es

**Abstract**—This is a summary of our article published in *Information Fusion* [4], which follows our previous works on the topic [1]–[3], presented to the Multi-Conference CAEPIA'18 - FINO'18 KeyWorks.

**Index Terms**—Multi-class classification, Pairwise Learning, One-vs-One, Decomposition Strategies, Ensembles, Classifier Selection

## I. SUMMARY

One way to address multi-class problems is by using decomposition strategies [5]. Among them, One-vs-One (OVO) excels as one of the most popular strategies. In OVO, the original multi-class problem is divided into as many subproblems as possible pairs of classes. Afterwards, an independent classifier is learned for each problem, whose outputs need to be combined to obtain the class for a given test instance.

This final combination, also known as aggregation, is a key factor as in every classifier ensemble. In the literature, several methods have been proposed to carry out the combination in OVO [1]. Among them, the voting strategy is the most intuitive one, where each classifier gives a vote for its predicted class and that reaching the largest number of votes is finally predicted.

Although several combination methods have been proposed in the literature for combining classifiers in OVO, none of them have dealt with the possibility of reducing the number of classifiers in the ensemble. That is, ensemble pruning has not been considered as an option because all the classifiers are supposed to be necessary.

For this reason, in this work our objective is two-fold:

- 1) To propose a transformation of the aggregation step in such a way that new examples are classified on the basis of the similarities among score-matrices.

- 2) To take advantage of this problem transformation to introduce the possibility of reducing the number of classifiers in OVO strategy without affecting the final accuracy of the model.

Therefore, we will change the way we look at the combination phase. Furthermore, instead of avoiding non-competent classifiers as in previous works [2], [3], we try to take advantage of them. Specifically, the aggregation is transformed so that the outputs of the classifiers are used as new inputs to another classification problem, which is the one considered to determine the final class labels of the dataset. After obtaining the outputs for every training example (each one stored in a score-matrix), new examples are classified with the class of the examples with the most similar score-matrix. This is why we named it as *Nearest Matrix Classification* (NMC). This modification allows us to reduce the number of classifiers and examples used in the classification step by developing an evolutionary classifier and instance selection model.

Backed-up by a thorough experimental study, we will show that almost 50% of the classifiers from OVO can be safely removed (depending on the base learning being considered and the specific problem). Moreover, the quality of the confidence degrees given by the base classifiers have a strong influence on the number of classifiers that can be removed without losing accuracy.

## ACKNOWLEDGEMENTS

This work was supported by the Spanish Ministry of Economy and Competitiveness under the project TIN2016-77356-P and TIN2017-89517-P (AEI/FEDER, UE).

## REFERENCES

- [1] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, F. Herrera, "An overview of ensemble methods for binary classifiers in multi-class



- problems: Experimental study on one-vs-one and one-vs-all schemes,” *Pattern Recognition* vol. 44, no. 8, pp. 1761–1776, 2011.
- [2] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, F. Herrera, “Dynamic classifier selection for one-vs-one strategy: Avoiding non-competent classifiers,” *Pattern Recognition*, vol. 46, no. 12, pp. 3412–3424, 2013.
- [3] M. Galar, A. Fernández, E. Barrenechea, F. Herrera, “DRCW-OVO: Distance-based relative competence weighting combination for one-vs-one strategy in multi-class problems,” *Pattern Recognition*, vol. 48, no. 1, pp. 28–42, 2015.
- [4] M. Galar, A. Fernández, E. Barrenechea, H. Bustince, F. Herrera, “NMC: nearest matrix classification – A new combination model for pruning One-vs-One ensembles by transforming the aggregation problem,” *Information Fusion*, vol. 36, pp. 26–51, 2017.
- [5] A.C. Lorena, A.C. Carvalho, J.M. Gama, “A review on the combination of binary classifiers in multiclass problems,” *Artificial Intelligence Review*, vol. 30, no. 1-4, pp. 19–37, 2008.

# A Pareto Based Ensemble with Feature and Instance Selection for Learning from Multi-Class Imbalanced Datasets

Alberto Fernandez

*DaSCI Andalusian Institute of Data Science  
and Computational Intelligence  
University of Granada  
Granada, Spain  
alberto@decsai.ugr.es*

Cristobal José Carmona

*Department of Computer Science  
University of Jaen  
Jaen, Spain  
ccarmona@ujaen.es*

Maria Jose del Jesus

*Department of Computer Science  
University of Jaen  
Jaen, Spain  
mjjesus@ujaen.es*

Francisco Herrera

*DaSCI Andalusian Institute of Data Science  
and Computational Intelligence  
University of Granada  
Granada, Spain  
herrera@decsai.ugr.es*

**Abstract**—This is a summary of our article published in *International Journal of Neural Systems* [1], to be considered as part of the Multi- Conference CAEPIA'18 - FINO'18 KeyWorks

**Index Terms**—Imbalanced Classification, Multi-class, Overlapping, Feature Selection, Instance Selection, Multi-objective Evolutionary Algorithms, Ensembles

## I. SUMMARY

In many classification tasks, we observe that some concepts are more difficult to be recognized than others [2]. This is related to the structure and inner characteristics of the data [3]. In particular, we may refer to the problem of imbalanced classification tasks as an important framework in Data Science problems [4]. It is found when some classes are underrepresented and the accuracy obtained for them is on average much lower than on the remaining classes [3].

As commented above, there are several reasons that, in conjunction with the imbalance, impose a hard restriction for the learning algorithms. The most significant one is the overlapping between classes [5]. This issue is strongly related with the attributes that represent the problem. Our hypothesis is that the use of feature selection will allow simplifying the boundaries of the problem by limiting the influence of those features that may create difficulties for the discrimination [6].

However, the imbalance class problem cannot be addressed by itself just by carrying out a feature selection. For this reason, it is also mandatory to perform a preprocessing of instances by resampling the training data distribution [7], avoiding a bias of the learning algorithm towards the majority

classes. In addition, we may go one step further to integrate both approaches into an ensemble-type classifier [8].

Obtaining the optimal set of features and instances for a given problem is not a trivial task. For this reason, an optimization procedure is often required. Among different approaches, recent works have shown the goodness of Multi-Objective Evolutionary Optimization (MOEA) procedures [9] due to their ability to perform a good exploration and exploitation of the solution space.

In our research, we proposed EFIS-MOEA, which stands for “Ensemble classifier from a Feature and Instance Selection by means of Multi-Objective Evolutionary Algorithm.” To do so, we embedded the C4.5 decision tree [10] in a wrapper procedure, applying the well-known NSGA-II multi-objective optimization algorithm [11].

The ultimate goal of our proposal was to provide a rule-based model that *maximizes the recognition of all individual classes*. This was achieved by focusing on the minority class clusters that were hard to identify. To do so, we focused on boosting the confidence of those rules associated with the former areas by means of the cleaning procedure, i.e. instance selection. In this way, the optimal criteria was minimizing the number of “bad” examples or, in other words, *maximizing the reduction of instances*. Additionally, and taking into account the findings made in [12], the coverage of the rules may imply capturing some of the non-related classes. We must point out that in order to obtain the quality of the recognition ability of the classifier, we computed MAUC metric as the macro-average of the pairwise AUC values of all pairs of classes:

$$\text{MAUC} = \frac{2}{m(m-1)} \sum_{i < j} \text{AUC}(C_i, C_j) \quad (1)$$

This work was supported by the Spanish Ministry of Economy and Competitiveness under the projects TIN2015-68454-R and TIN2017-89517-P, including European Regional Development Funds.



The basis of our methodology involved several components:

- 1) First, feature selection was devoted to simplify the overlapping areas easing the generation of rules to distinguish between the classes.
- 2) Selection of instances from all classes addressed the imbalance itself by finding the most appropriate class distribution for the learning task, as well as possibly removing noise and difficult borderline examples.
- 3) Finally, the non-dominated solutions of the Pareto front from the MOEA could be directly combined into an ensemble of classifiers.

We set up a fair validation framework for the novel EFIS-MOEA proposal, considering two different case studies in binary and multi-class problems. Several approaches from the state-of-the-art were chosen in order to contrast the results. Particularly, the SMOTE+ENN preprocessing approach [13] for binary class problems and multi-class problems (using a binarization scheme [14]), and both Global-CS [15] and AdaBoost.NC [16] for the multi-class case study. Finally, we must recall that the behavior of EFIS-MOEA was contrasted versus 1-FIS-MOEA, i.e. a classifier obtained by selecting the best solution of the Pareto in terms of M-AUC.

In Table I we show the results for the binary case study. We observe that the synergy between feature selection and instance selection boosts the performance of our approach versus the oversampling and cleaning carried out by SMOTE+ENN, especially for highly overlapped problems in which the absolute differences are almost 4 points on average.

TABLE I  
AVERAGE TRAINING-TEST RESULTS (AUC) AND STATISTICAL STUDY FOR BINARY IMBALANCED DATASETS.

Scenario	Method	AUC Train	AUC Test	Ranking	APV (Holm test)	W/T/L
Low overlap (F1 > 1.5) [30]	C4.5	.9510 ± .0253	.8892 ± .0661	94.00 (4)	.00000*	4/0/26
	C4.5-SMOTE+ENN	.9797 ± .0090	.9263 ± .0472	53.30 (2)	.00737*	8/0/22
	1-FIS-MOEA	<b>.9943 ± .0031</b>	.9195 ± .0514	65.47 (3)	.00005*	3/0/27
	EFIS-MOEA	.9906 ± .0072	<b>.9439 ± .0414</b>	29.23 (1)	*****	-/-
High overlap (F1 < 1.5) [36]	C4.5	.8437 ± .0454	.7352 ± .0726	113.78 (4)	.00000*	2/0/34
	C4.5-SMOTE+ENN	.9338 ± .0182	.7817 ± .0740	71.61 (2)	.00000*	3/0/33
	1-FIS-MOEA	<b>.9761 ± .0081</b>	.7749 ± .0757	79.22 (3)	.00000*	0/0/36
	EFIS-MOEA	.9717 ± .0100	<b>.8273 ± .0596</b>	25.39 (1)	*****	-/-

In Table II we show the results for the case study of multi-class problems. The findings extracted from this analysis is similar of that of the previous scenario. The goodness shown by our EFIS-MOEA approach is clear, as it is able to outperform all algorithms selected for comparison. The statistical results provide a strong support to the excellent capabilities for our approach. By taking advantage from all the solutions discovered in the optimization stage into an ensemble, results are significantly boosted with respect to the best classifier found in the MOEA search, i.e. 1-FIS-MOEA, which suffers from the curse of overfitting.

The results obtained by EFIS-MOEA were very competitive, especially for highly overlapped problems. The selection of instances allowed rebalancing the training set as well as to clean the low quality data, i.e. noisy and redundant examples. In addition, feature selection simplified the boundaries of the problem to manage the aforementioned overlapping issue.

TABLE II  
AVERAGE TRAINING-TEST RESULTS (M-AUC) AND STATISTICAL STUDY FOR MULTI-CLASS IMBALANCED DATASETS.

Method	AUC Train	AUC Test	Ranking	APV (Holm test)	W/T/L
C4.5	.9006 ± .0141	.8157 ± .0297	102.54 (6)	.00000*	2/0/22
OVO-SMOTE+ENN	.9369 ± .0136	.8292 ± .0352	74.58 (5)	.00725*	6/0/19
Global-CS	<b>.9726 ± .0060</b>	.8324 ± .0346	72.48 (3)	.01206*	4/0/20
AdaBoost.NC	.9530 ± .0147	.8233 ± .0319	69.06 (2)	.02597*	8/0/16
1-FIS-MOEA	.9715 ± .0041	.8299 ± .0355	74.08 (4)	.00820*	5/0/19
EFIS-MOEA	.9691 ± .0058	<b>.8441 ± .0322</b>	42.25 (1)	*****	-/-

The behavior of EFIS-MOEA is excelled as it was shown to outperform the state-of-the-art algorithms, especially the AdaBoost.NC algorithm, a robust approach in this context.

## REFERENCES

- [1] A. Fernandez, C. Carmona, M. del Jesus, and F. Herrera, *International Journal of Neural Systems*, vol. 27, pp. 1750 028:1–1750 028–21, 2017.
- [2] M. Galar, A. Fernandez, E. Barrenechea, and F. Herrera, “Empowering difficult classes with a similarity-based aggregation in multi-class classification problems.” *Inf. Sci.*, vol. 264, pp. 135–157, 2014.
- [3] V. Lopez, A. Fernandez, S. Garcia, V. Palade, and F. Herrera, “An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics,” *Inf. Sci.*, vol. 250, no. 20, pp. 113–141, 2013.
- [4] P. Branco, L. Torgo, and R. P. Ribeiro, “A survey of predictive modelling under imbalanced distributions,” *ACM Computing Surveys*, vol. 49, no. 2, pp. 31:1–31:50, 2016.
- [5] V. Garcia, R. Mollineda, and J. S. Sanchez, “On the k-NN performance in a challenging scenario of imbalance and overlapping,” *Pattern Analysis Applications*, vol. 11, no. 3–4, pp. 269–280, 2008.
- [6] S. Alshomrani, A. Bawakid, S.-O. Shim, A. Fernandez, and F. Herrera, “A proposal for evolutionary fuzzy systems using feature weighting: Dealing with overlapping in imbalanced datasets.” *Knowledge-Based Systems*, vol. 73, pp. 1–17, 2015.
- [7] R. C. Prati, G. E. A. P. A. Batista, and D. F. Silva, “Class imbalance revisited: a new experimental setup to assess the performance of treatment methods,” *Know. and Inform. Syst.*, vol. 45, no. 1, pp. 247–270, 2015.
- [8] M. Galar, A. Fernandez, E. Barrenechea, H. Bustince, and F. Herrera, “A review on ensembles for class imbalance problem: Bagging, boosting and hybrid based approaches,” *IEEE Transactions on System, Man and Cybernetics Part C: Applications and Reviews*, vol. 42, no. 4, pp. 463–484, 2012.
- [9] A. Zhou, B. Y. Qu, H. Li, S. Z. Zhao, P. N. Suganthan, and Q. Zhangd, “Multiobjective evolutionary algorithms: A survey of the state of the art,” *Swarm and Evol. Comp.*, vol. 1, no. 1, pp. 32–49, 2011.
- [10] J. Quinlan, *C4.5: Programs for Machine Learning*. Morgan Kaufmann, 1993.
- [11] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, “A fast and elitist multiobjective genetic algorithm: Nsga-ii,” *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.
- [12] A. Manukyan and E. Ceyhan, “Classification of imbalanced data with a geometric digraph family,” *Journal of Machine Learning Research*, vol. 17, pp. 1–40, 2016.
- [13] A. Fernandez, S. Garcia, F. Herrera, and N. Chawla, “Smote for learning from imbalanced data: Progress and challenges. marking the 15-year anniversary,” *Journal of Artificial Intelligence Research*, vol. 61, pp. 863–905, 2018.
- [14] A. Fernandez, V. Lopez, M. Galar, M. J. del Jesus, and F. Herrera, “Analysing the classification of imbalanced data-sets with multiple classes: Binarization techniques and ad-hoc approaches?” *Knowledge-Based Systems*, vol. 42, pp. 97–110, 2013.
- [15] Z.-H. Zhou and X.-Y. Liu, “On multi-class cost-sensitive learning,” *Computational Intelligence*, vol. 26, no. 3, pp. 232–257, 2010.
- [16] S. Wang and X. Yao, “Multiclass imbalance problems: Analysis and potential solutions,” *IEEE Transactions on System Man and Cybernetics: Part B*, vol. 42, no. 4, pp. 1119–1130, 2012.



# **I Workshop en Aplicaciones de la Inteligencia Artificial para la Industria 4.0**

JAVIER DEL SER  
JOSE ANTONIO LOZANO







## Academic contributions in supply chain management: A university analysis

**Keivan Amirbagheri**

*Department of Economics and Business, Faculty of Economics and Business, University of Barcelona, Av. Diagonal 690, 08034 Barcelona, Spain*

*kamirbam7@alumnes.ub.edu*

**José M. Merigó**

*Department of Management Control and Information Systems, School of Economics and Business, University of Chile, Av. Diagonal Paraguay 257, 8330015 Santiago, Chile*

*jmerigo@fen.uchile.cl*

**Enrique Herrera-Viedma**

*Department of Computer Science and Artificial Intelligence, University of Granada, Granada, Spain*

*viedma@decsai.ugr.es*

### Abstract

The studies related to supply chain management have experienced a huge growth during the last 27 years. So, it seems necessary to investigate the diverse dimensions of this growth to understand better the existing trends also the possible patterns. The purpose of this study is to analyze the leading and productive worldwide universities. To do so the universities are studied globally, periodically and in some select significant journals in supply chain management area. The data of Web of Science is analyzed between 1990 to 2017. The results show that although in general American universities have the highest share among others, but Asian universities and especially Chinese ones start a rapid growth and it is predictable that in future they become leaders. Besides, European universities also have the next position according to the number of publications.

**Keywords:** Supply chain management, bibliometrics, Web of Science, VOS viewer, universities

### 1. Introduction

Since Oliver & Webber (1982) introduced the concept of supply chain management (SCM), many scholars work on this discipline and its different dimensions. These studies are dedicated to diverse aspects throughout a spectrum from studying the importance of each element of SCM (Frohlich & Westbrook, 2001) to present an appropriate framework for SCM and its performance measurement (Lambert & Cooper, 2000; Gunasekaran et al. 2004) to evaluate its impact on the organizational performance (Li et al, 2006).

Due to this level of investigation and based on an increasing number of the publications in this area, it

seems essential to analyze the details about the papers and the existing trends in this area and to understand about the leading universities (Cancino et al. 2017a). Although there are some reviews on SCM by using diverse methods, none of them explain about the issue of leading universities.

In this study we analyze the top leading universities all around the world based on their influence and productivity from different point of views: their global positions, a comparative study about the universities in terms of various indicators, periodic study of the universities and the performance of the universities in several journals specialized in SCM. So, to achieve to these results we use bibliometric analysis (Broadus, 1987; Pritchard, 1969) in SCM research between 1990 and 2017. Web of Science (WoS) as a comprehensive database was selected to begin the process of search. All the obtained data are the articles that published in academic journals. The search process starts at the same time with the keywords that are: “supply chain” or “supply chain management” or “SCM” and some specialized journals of the area such as: Supply Chain Management: an International Journal, Journal of Supply Chain Management, International Journal of Supply Chain Management, International Journal of Information Systems and Supply Chain Management, Journal of Humanitarian Logistics and Supply Chain Management, Journal of Transport and Supply Chain Management and Operations and Supply Chain Management: an International Journal. The next step is excluding the papers of 2018, then filtering by 16 categories of WoS related to the area and finally filter those results that are: article, letter, note and review based on the classification of WoS.

The results of the study show that according to the number of the leading universities, American universities have the highest share, almost half of the top 50 universities. After them Chinese universities

are obtaining the second position with around 20% of the leading universities.

The rest of the article is as follows. Literature review section analyze the related literature to SCM research area and bibliometric methods. Bibliometric methods section reviews the bibliometric methods. Then in results section, the universities analyze comprehensively globally, periodically and in some individual journals. Finally, the conclusions section is dedicated to report the findings and contribution of this study.

## 2. Literature review

Bibliometric analysis based on its capability to prepare diverse data, as an efficient method is used in literature in many disciplines. To understand this concept and its several aspects thoroughly, many scholars try to define it based on their opinion. Pritchard (1969), defined it as “to shed light on the processes of written communication and of the nature and course of development of a discipline, by means of counting and analyzing the various facets of written communication ... the application of mathematics and statistical methods to books and other media of communication” but according to Broadus (1987), bibliometrics is “the quantitative study of physical published units, or of bibliographic units, or of surrogates of either”.

There are some samples that apply bibliometric method to study the ranking of the universities all over the world not only in diverse disciplines of economic and management, but through some works that analyze the trend of different journals during the time. Cancino et al. (2017a) investigate about the universities that are most productive and influential in innovation research. Additionally, Cancino et al. (2017b) analyze the performance of Computers and Industrial Engineering during 40 years from many aspects including trend of universities. In another example, Martínez-López et al. (2018) with the motivation of the fiftieth year of European Journal of Marketing, do a bibliometric analysis that one of part of that work belongs to the universities. Likewise, two very same works also via a bibliometric study analyze the situation of the universities respectively in Technovation and Information Sciences (Merino et al. 2006; Merigó et al. 2018).

Based on this reality that although there are some related bibliometric works on SCM, there is no specialized study on the trend of the leading universities in this research area. Via this work we try to analyze the universities not only in the scope of the USA or Europe, but we have a worldwide opinion to investigate them.

## 3. Bibliometric methods

There are several definitions that can explain bibliometrics concept. According to Broadus (1987), bibliometrics is “the quantitative study of physical published units, or of bibliographic units, or of surrogates of either”. To this end, the papers could be analyzed based on different criterion such as (publications, citations and h-index) (Cancino et al. 2017a). During the process of literature review, there are many examples that have focused on one of these criteria. Chao et al. (2007), Li et al. (2009) and Fahimnia et al. (2015), have established their works based on number of publications. Whilst, there are some studies that focus on citation analysis (Xie et al. 2008; Podsakoff et al. 2008). Besides, since Hirsch (2005) introduced *h*-index as an indicator to combine the number of articles and citations, it becomes a popular indicator to classify the papers (Alonso et al. 2009). This indicator expresses that “if a set of articles have an *h*-index of 10; it means that ten studies of the set have received ten or more citations” (Merigó et al. 2016). This study is based on the number of publications.

The data gathering process was done on April 2018. The selected keywords with the purpose of covering as much publications possible in the area are “supply chain” or “supply chain management” or “SCM” from one side and the other constraint toward a high quality search is including the results of some related journals from the other side such as: Supply Chain Management: an International Journal, Journal of Supply Chain Management, International Journal of Information Systems and Supply Chain Management, Journal of Humanitarian Logistics and Supply Chain Management, Journal of Transport and Supply Chain Management and Operations and Supply Chain Management: an International Journal between 1990 to 2017.

It is important to say that according to the obtained results, some modifications seem necessary.



For example, the authors instead of four countries “England”, “Wales”, “Scotland” and “North Ireland” just considered one country as UK. The same story exists for “China” and “Hong Kong” that the country that appears in a table as China is a combination of both.

VOS viewer is a powerful software that is used to report visually the countries of the study through bibliographic coupling, citations and co-authorship analysis (Van Eck & Waltman 2010). Bibliographic strength between two papers is defined as the number of common references cited by both papers (Morris 2005). Besides, “co-authorship analysis represents the volume of publications of a set of variables and how they are connected between them” (Merigó et al. 2016).

With the aim of presenting the obtained results in a graphical form, VOS viewer generates visual reports. Figure 1 to 20 represent the graphics that belong to the most influential journals in SCM research area, global trend of the universities, their periodic trend and their situation in the selected individual journals. Note that in the literature, there is other software that could be used for mapping the bibliographical material (Cobo et al. 2011; 2012).

### 3. Results

#### 3.1. Leading universities in SCM research

During the period of the analysis there were a plenty of universities that publish papers in SCM area. It is possible to rank the universities based on different indicators. Table 1 gives a comprehensive report around the top 50 universities in SCM research with a global overview. It is noticeable that the ranking is based on *h*-index. To enrich this table, some other data are also available in this table. Besides the total publications, total citation and *h*-index of the leading countries, these indicators are calculated also in top 10 journals of the area to understand the portion of each university in them. Moreover, the ranking of each university based on QS ranking and Shanghai ranking is also reported. The benefit of ranking analysis is giving a comparative idea of the position of the universities in SCM area against general position.

As can be seen in Table 1, most of the universities are American so that as an example 6 of

10 top universities are American. However, it is noteworthy to say that the first leading university is Hong Kong Polytechnic University that is a Chinese university. From top 50 universities in this area, 46% of them are American and 18% are Chinese. Although Cardiff University is the third university in this list, but it is important to say that among all, only 8% of the universities are British.

Although the ranking is based on *h*-index and in this item the difference between the first and second university is not that high, but in terms of publication it is important to say that, Hong Kong Polytechnic University has published almost 2 times more than Michigan State University as the second top university. Besides, there are the other examples that are high in number of publications and not in *h*-index. One of these universities is Indian Institute of Technology IIT that according to *h*-index is the 19<sup>th</sup> university in the ranking but based on the number of publications is the 4<sup>th</sup> one.

The other interesting item to analyze is the situation of each universities in the top 10 journals of this discipline. The purpose of this analysis is to know on what level the top universities publish in top journals in SCM research. With a quick glance the trend of American universities is not completely the same as the global overview. Based on the Table 1, there are some of them which don't have any publication among these top journals. From the other side, as an example Arizona State University has published almost all his publications (99%) in these top 10 journals. On the other hand, although Hong Kong Polytechnic University has published less than 50% of his articles in the top 10 journals, but the portion of his *h*-index from these journals is quite acceptable (around 71%).

As a supportive information and with the help of VOS viewer software, Figure 1 represents the bibliographic coupling of the universities with a threshold of 134.

#### 3.2. Periodical analysis of leading universities

The purpose of this section is to analyze the trend of each university during the time to study better and more profound their position from the first year till the last year of the analysis. To this end, based on this fact that publishing the papers began in 1990, we consider three periods: 1990 to 1999, 2000 to 2009 and 2010 to 2017.

During 1990-1999, American universities have the highest share of the top universities. It is interesting to know that in this period, Hong Kong Polytechnic University that is globally on the top of the list of leading universities even is not among the top 40 universities.

The analysis of the leading universities between 2000 and 2009 also shows that, although again most of the universities are American, but some Asian universities were entered among the leading universities such that among top ten, four of them are Asian.

The significant point of the period between 2010 and 2017 is the presence of three Asian universities as top three universities of this classification. This occurrence and the trend of last periods can express that during the next years the domination of Asian universities will be more and more. Additionally, the number of American universities is still high but in comparison with the last periods decreased and are substituted by some universities from Asia and Europe. In this period almost half of the universities are Asian (45%) however this percentage for the last period was 27%.

### 3.3. Individual journal analysis of the leading universities

One of the interesting analysis that could shed light to understand the position and the behavior of the universities in SCM research area is analyzing them in the important journals of the field.

To this end, we analyze the leading universities in two professional journals of the field: Supply Chain Management: An International Journal and Journal of Supply Chain Management. In Supply Chain Management: An International Journal most of the universities are European and among them there are a lot of British universities, around half of them. The other interesting item about this list is the presence of some Australian universities that have a good share. In return for the Journal of Supply Chain Management 24 universities from 30 are American and it is 80% and the other 6 universities are European.

The next two journals that are analyzed are International Journal of Production Economics and International Journal of Production Research. The reason of choosing these journals is that because they are on the top of the list of most publishing journals

in SCM area. For the first journal it is noteworthy to say that the distribution of Chinese and European is almost the same and the small number of American universities.

Table 1 - Most influential universities in SCM

R	University	COU	H	TC	TP
1	Hong Kong Polytechnic U.	CHN	59	14214	504
2	Michigan State U.	USA	54	11697	286
3	Cardiff U.	GBR	50	8155	236
4	U. North Carolina	USA	47	9678	275
5	Arizona State U.	USA	46	8975	224
6	Pennsylvania State U.	USA	40	6646	205
7	Chinese Academy of Sciences	CHN	40	4580	150
8	Stanford U.	USA	40	9149	98
9	Georgia Institute of Technology	USA	38	6647	145
10	U. Hong Kong	CHN	37	5246	198
11	Carnegie Mellon U.	USA	37	4983	118
12	U. Minnesota Twin Cities	USA	37	4205	115
13	U. Tennessee Knoxville	USA	36	4833	167
14	Cranfield U.	GBR	36	4896	165
15	Indian Institute of Technology IIT	IND	35	5035	274
16	U. California Berkeley	USA	35	4807	124
17	U. Maryland College Park	USA	35	4459	109
18	U. Southern Denmark	DNK	34	4031	151
19	Ohio State U.	USA	34	5170	139
20	MIT	USA	34	3924	127
21	Chinese U. Hong Kong	CHN	34	4066	104
22	Erasmus U. Rotterdam	NLD	33	4100	103
23	U. Texas Austin	USA	33	3417	89
24	Insead Business School	FRA	33	4794	87
25	National U. Singapore	SGP	32	4197	149
26	Texas A&M U. College Station	USA	32	3753	147
27	U. Manchester	GBR	32	3483	123
28	Auburn U.	USA	32	3413	113
29	U. Cambridge	GBR	32	2991	111
30	U. Texas Dallas	USA	32	3051	109
31	City U. Hong Kong	CHN	31	3304	183
32	U. Science and Technology of China	CHN	31	3252	140
33	Hong Kong U. Science and Technology	CHN	31	3295	125
34	Shanghai Jiao Tong U.	CHN	30	2998	142
35	U. Michigan	USA	30	4093	140
36	U. Montreal	CAN	30	3154	130
37	U. Florida	USA	29	2912	128
38	Iowa State U.	USA	28	2816	104
39	ETH Zurich	CHE	28	2334	100
40	Tsinghua U.	CHN	27	2389	144
41	Polytechnic U. Milan	ITA	27	2471	120
42	U. Arkansas Fayetteville	USA	27	2430	117
43	Eindhoven U. Technology	NLD	27	2938	103
44	Linkoping U.	SWE	27	2499	87
45	Nanyang Technological U.	SGP	26	2888	128
46	Aalto U.	FIN	26	2233	112
47	U. Padua	ITA	26	2204	88
48	North Carolina State U.	USA	26	3435	84
49	Amirkabir U. Technology	IRN	25	2210	133
50	Purdue U.	USA	25	3310	123

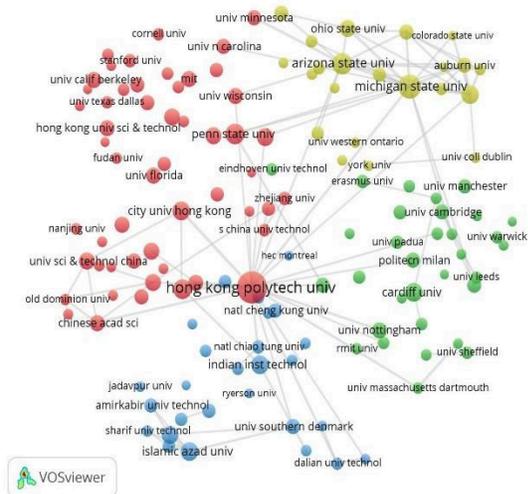
Abbreviations: R = Rank; COU = Country; HI = h-index (in SCM); TP and TC = total number of publications and citations (in SCM).

In this journal, Hong Kong Polytechnic University is a leader and the difference of his publications with the second and third universities is meaningful so that



for example this university publish more than three times in comparison with the third university that is Polytechnic University of Milan. In International Journal of Production Research, the dispersion of the universities is almost the same with this difference that the Chinese universities are not the only Asian universities and some Indian and Iranian universities also exist among them. Besides that, the top three universities in this list are Asian. Although in this journal, Hong Kong Polytechnic University is the first based on the number of publication, but University of Hong Kong has a better performance in terms of total citation and *h*-index.

In Journal of Cleaner Production, there is only one American university among the top 30 universities and the rest of them are European and Asian universities. Also, there are two Brazilian universities that are consecutively 8<sup>th</sup> and 11<sup>th</sup>. In the list of Computers and Industrial Engineering 26 of 30 universities are Asian following by two Canadian universities, one American and one French. Among Asian universities, although Indian Institute of Technology IIT is the first university and publishes more than two times than the second university but in terms of number of universities, Chinese and Iranian Universities have a better position.



**Fig 1.** Bibliographic coupling of the universities in SCM research- threshold: 134, connections: 100

#### 4. Conclusions

This study provides a comprehensive bibliometric analysis of the leading universities of all the world in supply chain management research area between 1990 and 2017. With a purpose of obtaining a comprehensive understanding about the field, total number of publications, total citations and *h*-index are analyzed.

Other results of this analysis belong to the universities' share in top 10 journals of the area. Although American universities have the highest share in comparison with the others, but the obtained results of top 10 journals are not in compliance with the global results. As an example, there are some universities that have even zero publications in top journals but vice versa as an example, Arizona State University publishes 99% of his papers in these 10 top journals. in addition, Hong Kong Polytechnic University as a leader of the leading universities publishes less than half of his papers among top 10 journals.

First, analysis focuses on a global perspective to understand the trend of the publications during the years of the study. Among the leading universities in this classification Hong Kong Polytechnic University is the first university of the list but based on the results, American universities have the most share among the others and after them Chinese universities have the next position in terms of total publications. However, the British universities have a low share in comparison with the others.

Then, our study focuses on periodical analysis of the universities' positions where during three periods, the universities are analyzed. A general analysis around these periods expresses that in the very first period of study, American universities are indisputably leaders of the universities which publish papers in SCM research but year by year this trend changes so that during the years of last period most of the universities are Asian and especially Chinese. From this trend it is possible to conclude that the future of the leading universities in this area, belongs to Asian universities.

Finally, the obtained results of the universities in some individual journals are studied. The analysis demonstrates that in some journals or group of journals American universities have the highest share, but in some of theme Chinese universities seize the top position in terms of number of the universities. There are two groups of journals

(Manufacturing Journals and other SCM Journals) that consecutively the top universities in them belong to Iran and South Africa.

## References

- Alonso, S., Cabrerizo, F. J., Herrera-Viedma, E., & Herrera, F. (2009). H-index: A review focused on its variants, computation, and standardization for different scientific fields. *Journal of Informetrics*, 3, 273–289.
- Broadus, R. (1987). Toward a definition of “bibliometrics”. *Scientometrics*, 12(5-6), 373-379.
- Cancino, C. A., Merigó, J. M., & Coronado, F. C. (2017a). A bibliometric analysis of leading universities in innovation research. *Journal of Innovation & Knowledge*, 2(3), 106-124.
- Cancino, C. A., Merigó, J. M., Coronado, F. C., Dessouky, Y., & Dessouky, M. (2017b). Forty years of Computers & Industrial Engineering: A bibliometric analysis. *Computers & Industrial Engineering*, 113, 614-629.
- Chao, C. C., Yang, J. M., & Jen, W. Y. (2007). Determining technology trends and forecasts of RFID by a historical review and bibliometric analysis from 1991 to 2005. *Technovation*, 27(5), 268-279.
- Cobo, M. J., Lopez-Herrera, A. G., Herrera-Viedma, E., & Herrera, F. (2011). Science mapping software tools: Review, analysis and cooperative study among tools. *Journal of the American Society for Information Science and Technology*, 62, 1382–1402.
- Cobo, M. J., Lopez-Herrera, A. G., Herrera-Viedma, E., & Herrera, F. (2012). SciMAT: A new science mapping analysis software tool. *Journal of the American Society for Information Science and Technology*, 63, 1609–1630.
- Fahimnia, B., Sarkis, J., & Davarzani, H. (2015). Green supply chain management: A review and bibliometric analysis. *International Journal of Production Economics*, 162, 101-114.
- Frohlich, M. T., & Westbrook, R. (2001). Arcs of integration: an international study of supply chain strategies. *Journal of Operations Management*, 19(2), 185-200.
- Gunasekaran, A., Patel, C., & Mc Gaughey, R. E. (2004). A framework for supply chain performance measurement. *International Journal of Production Economics*, 87(3), 333-347.
- Lambert, D. M., & Cooper, M. C. (2000). Issues in supply chain management. *Industrial Marketing Management*, 29(1), 65-83.
- Li, S., Ragu-Nathan, B., Ragu-Nathan, T. S., & Rao, S. S. (2006). The impact of supply chain management practices on competitive advantage and organizational performance. *Omega*, 34(2), 107-124.
- Li, L. L., Ding, G., Feng, N., Wang, M. H., & Ho, Y. S. (2009). Global stem cell research trend: Bibliometric analysis as a tool for mapping of trends from 1991 to 2006. *Scientometrics*, 80(1), 39-58.
- Martínez-López, F. J., Merigó, J. M., Valenzuela-Fernández, L., & Nicolás, C. (2018). Fifty years of the European Journal of Marketing: a bibliometric analysis. *European Journal of Marketing*, 52(1/2), 439-468.
- Merigó, J. M., Cancino, C. A., Coronado, F., & Urbano, D. (2016). Academic research in innovation: a country analysis. *Scientometrics*, 108(2), 559-593.
- Merigó, J. M., Pedrycz, W., Weber, R., & de la Sotta, C. (2018). Fifty years of Information Sciences: A bibliometric overview. *Information Sciences*, 432, 245-268.
- Merino, M. T. G., Do Carmo, M. L. P., & Álvarez, M. V. S. (2006). 25 Years of Technovation: Characterisation and evolution of the journal. *Technovation*, 26(12), 1303-1316.
- Morris, S. A. (2005). Manifestation of emerging specialties in journal literature: A growth model of papers, references, exemplars, bibliographic coupling, co citation, and clustering coefficient distribution. *Journal of the Association for Information Science and Technology*, 56(12), 1250-1273.
- Oliver, R. K., & Webber, M. D. (1982). Supply-chain management: logistics catches up with strategy. *Outlook*, 5(1), 42-47.
- Podsakoff, P. M., MacKenzie, S. B., Podsakoff, N. P., & Bachrach, D. G. (2008). Scholarly influence in the field of management: A bibliometric analysis of the determinants of university and author impact in the management literature in the past quarter century. *Journal of Management*, 34(4), 641-720.
- Pritchard, A. (1969). Statistical bibliography or bibliometrics. *Journal of Documentation*, 25(4), 348-349.
- Van Eck, N. J., & Waltman, L. (2010). Software survey: VOS viewer, a computer program for bibliometric mapping. *Scientometrics*, 84(2), 523-538.
- Xie, S., Zhang, J., & Ho, Y. S. (2008). Assessment of world aerosol research trends by bibliometric analysis. *Scientometrics*, 77(1), 113-130.



# Operadores lingüísticos OWA-RIM para la diagnosis de fallos en plantas complejas

A. Sánchez-Fernández, M.J. Fuente, G.I. Sainz-Palmero

*Dpto. de Ingeniería de sistemas y Automática*

*Universidad de Valladolid*

Valladolid, España

alvsan, mjfuente, gresai@eii.uva.es

Jose Manuel Benitez

*Dpto de Ciencias de la Computación e Inteligencia Artificial*

*Universidad de Granada*

Granada, España

j.m.benitez@decsai.ugr.es

**Abstract**—En este trabajo se afronta el problema de la detección e identificación de fallos en plantas industriales complejas. Dicho problema se aborda como una toma de decisiones basada en operadores lingüísticos OWA, lo cual permite fusionar diversos métodos de identificación de fallos (FI) alternativos. De esta manera la diagnosis de fallos resulta más robusta, y por otro lado el aspecto lingüístico de los operadores manejados encaja fácilmente en el contexto de la detección e identificación de fallos. La identificación se lleva a cabo usando varios métodos de FI muy utilizados, la solución de cada método se agrega usando operadores del tipo Ordered Weighed Average (OWA), basados en cuantificadores Regular Increasing Monotone (RIM). En este artículo se ha hecho una comparativa de los términos lingüísticos más conocidos para implementar estos operadores OWA-RIM en el contexto de la identificación de fallos. Esto se ha aplicado a un benchmark de plantas depuradoras de aguas residuales.

**Palabras clave**—Identificación de fallos, Fusión de información, OWA, Cuantificadores.

## I. INTRODUCCIÓN

En cualquier tipo de instalaciones, plantas industriales, maquinaria, etc. existe el problema de verificar si tanto el propio sistema como sus dispositivos de control están trabajando correctamente y sin fallos. Además, en caso de detectar algún fallo, es necesario localizar los puntos de la planta en los que ha aparecido el fallo, esto es, analizar las causas del comportamiento defectuoso. Por otro lado, en muchos casos es difícil y costoso detener la instalación, y por tanto, se debe conocer cómo evoluciona el sistema después del fallo para tomar la decisión de parar la planta para reparar el fallo o continuar trabajando con ella si el fallo no afecta a la integridad de la misma, ni a la calidad del proceso, ni resulta peligroso para el personal.

En sistemas de cierta envergadura se cuenta con gran cantidad de variables y todas ellas deben ser monitorizadas para detectar y localizar cualquier problema. Por todo esto se hace imprescindible tener una herramienta que facilite la diagnosis de fallos en la planta.

En el momento en el que un fallo es detectado se requiere saber dónde está el problema. Tradicionalmente los diagramas de contribución [1] han sido la herramienta más utilizada para

localizar fallos basadas en datos, y en concreto en el contexto de PCA. Algunos autores han propuesto otras soluciones: en [2] se combinan los estadísticos tradicionales del PCA ( $T^2$  y  $Q$ ) en un nuevo estadístico  $\varphi$ , en [3] se desarrolló el método de contribución basada en la reconstrucción, y en [4] se introdujeron los diagramas de contribución modificados. A pesar de toda esta variedad de métodos existentes no hay una técnica universal, cada una tiene ventajas e inconvenientes. En este contexto se plantea el uso de múltiples técnicas de identificación de fallos y la “fusión” de sus resultados para así conseguir una diagnosis más robusta. Este trabajo está basado en la metodología propuesta en [5] de identificación de fallos, donde la diagnosis final es una toma de decisiones multicriterio usando operadores lingüísticos OWA (Ordered Weighted Average)-Regular Increasing Monotone (RIM), [6].

La diagnosis [5] se basa en dos procesos de identificación del fallo, uno al detectarse éste, y otro una vez que la planta ha evolucionado en condiciones de fallo y llega a un nuevo estado estacionario. En el primer caso, sólo se tienen en cuenta las variables afectadas por el fallo en los primeros instantes. En el segundo caso, se tienen en cuenta otras variables que serán las que se verán afectadas por la propagación del fallo a lo largo de la instalación. El objetivo es conocer el origen del fallo y la posterior evolución del mismo a través del sistema. Algunos autores realizan únicamente la identificación en el instante de detección del fallo [1], mientras que otros la realizan a lo largo de un período de tiempo extenso después de dicha detección: Yue et al. introdujeron el índice de reconstrucción [2], Alcalá et al. ampliaron el trabajo acerca de dicho índice [3], Liu et al. aplicaron diagramas de contribución modificados [4], Dunia et al. trabajaron con los subespacios del fallo [7].

La novedad presentada en este trabajo consiste en la aplicación de una amplia variedad de operadores lingüísticos OWA-RIM: *Existe, Todos, Al menos  $\alpha, \dots$*  para comprobar las prestaciones de dichos cuantificadores y ver si obtienen una buena diagnosis: en términos de una correcta identificación de las variables responsables del fallo y de separabilidad entre las variables candidatas al fallo y el resto de variables de la planta.

El resto de este artículo está organizado de la siguiente manera: la Sección II explica los aspectos teóricos en los que se basa este trabajo. La metodología de diagnosis se

Este trabajo ha sido financiado parcialmente por el Ministerio de Economía y Competitividad del Gobierno español y por el Fondo Europeo de Desarrollo Regional (FEDER) a través de los proyectos: DPI2015-67341-C2-2-R, TIN2013-47210-P, TIN2016-81113-R.

explica brevemente en la Sección III. En la Sección IV se explica la planta donde se ha probado el método propuesto y los resultados obtenidos. Finalmente, las conclusiones de este trabajo están contenidas en la Sección V.

## II. TEORÍA

### A. Análisis de Componentes Principales

El Análisis de Componentes Principales (PCA) [8] es una técnica muy utilizada para reducción de la dimensionalidad, construcción de modelos, análisis de datos, así como para detectar y diagnosticar fallos [1], [3], [4], [9].

El modelo PCA parte de una matriz  $\mathbf{X}$  ( $n \times m$ ) con datos de la planta en condiciones normales, que es normalizada a media 0 y varianza 1:  $\mathbf{X}^{norm}$ . Su matriz de covarianza se descompone en valores singulares, dando como resultado:

$$\mathbf{S} = \frac{1}{(n-1)} (\mathbf{X}^{norm})^T \mathbf{X}^{norm} = \mathbf{V} \mathbf{\Lambda} \mathbf{V}^T \quad (1)$$

donde  $\mathbf{\Lambda}$  ( $m \times m$ ) es una matriz diagonal con los valores singulares, y  $\mathbf{V}$  ( $m \times m$ ) contiene los vectores propios. Si se elige un número  $a$  de elementos de  $\mathbf{\Lambda}$  que representen un porcentaje suficientemente alto de la varianza total de los datos, se obtiene una matriz  $\mathbf{\Lambda}_a$ . Las  $a$  primeras columnas de  $\mathbf{V}$ , forman la matriz de cargas  $\mathbf{P}$ .

1) *Detección de fallos*: La opción más usada para realizar la detección de fallos con PCA se basa en el cálculo de las estadísticas  $T^2$  y  $Q$  como sigue [9], [1]:

$$T^2 = z^T \mathbf{P} \mathbf{\Lambda}_a^{-1} \mathbf{P}^T z \quad (2)$$

$$Q = r^T r, \quad r = (\mathbf{I} - \mathbf{P} \mathbf{P}^T) z^T \quad (3)$$

Siendo  $z$  una nueva observación e  $\mathbf{I}$  la matriz identidad. Si los valores de  $T^2$  y  $Q$  están por debajo de unos umbrales  $T_\alpha^2$  y  $Q_\alpha$ , el sistema trabaja en condiciones normales.

Hay un tercer estadístico, que es combinación de los dos anteriores:  $\varphi$  [2].

$$\varphi = \frac{Q}{Q_\alpha} + \frac{T^2}{T_\alpha^2} \quad (4)$$

Los respectivos umbrales que no se deben superar se pueden calcular según lo expuesto en [8], [2].

La alarma saltará para  $T^2$ ,  $Q$  o  $\varphi$  cuando uno de ellos sobrepase su umbral un número determinado de observaciones consecutivas. Ese número de observaciones consecutivas debe escogerse para evitar falsas alarmas pero no debe retrasar mucho la detección.

Los valores de los umbrales calculados antes son teóricos, y es necesario reajustarlos a valores más realistas usando los datos disponibles. Para ello, se toman datos del sistema funcionando sin fallo y se ajusta un umbral de modo que sólo un  $\alpha$  % de las observaciones supere dicho umbral.

2) *Identificación de fallos*: Después de detectar un fallo, es necesario identificar las variables responsables del mismo. El análisis de contribuciones [1] es una de las técnicas más utilizadas para diagnosticar fallos. Se basa en la influencia de cada variable del sistema en el fallo. Las variables con mayor contribución al estadístico fuera de control (que ha detectado el fallo) son las responsables. Además de dicho método existen varios otros métodos que permiten identificar las variables responsables del fallo, los utilizados en este artículo se describen a continuación.

a) *Contribuciones a  $T^2$* : En la observación  $x$ , para cada una de los componentes principales normalizados de más alto valor se calculan las contribuciones de cada variable  $x_j$  en el componente principal normalizado  $a$  como [1]:

$$cont_{a,j} = \frac{t_a}{(\sigma_a)^2} (x_j - \mu_j) \quad (5)$$

si es negativa,  $cont_{a,j}$  se deja a cero. Se calcula la contribución total de cada variable  $j$ :

$$CONT_j = \sum_{a=1}^n cont_{a,j} \quad (6)$$

Las variables con la mayor contribución serán las que hayan influido más en la aparición del fallo.

b) *Errores normalizados de las variables*: Si una observación  $x$  tiene un valor del estadístico  $Q$  que supera el umbral, la contribución de cada variable se calcula como el cuadrado del error normalizado de cada variable  $x_j$ , [1] que es:

$$cont_{x_j} = (\hat{x}_j - x_j)^2 = e_j^2 \quad (7)$$

donde  $\hat{x}_j$  es el valor de la variable predicha por el modelo PCA y  $e_j$  es el error de predicción,

c) *Contribución a  $\varphi$* : La contribución a  $\varphi$  de la variable  $i$  se calcula como [3]:

$$c_i^\varphi = \left( \xi_i^T \Phi^{\frac{1}{2}} x \right)^2 \quad (8)$$

donde  $\xi_i$  es la  $i$ -ésima columna de la matriz identidad.

d) *Índices basados en reconstrucción*: El índice basado en la reconstrucción (RBC) [3] para una variable  $i$  se obtiene de la siguiente manera:

$$RBC_i^{index} = x^T M \xi_i (\xi_i^T M \xi_i)^{-1} \xi_i^T M x \quad (9)$$

donde  $x$  es la observación actual y la matriz  $M$  se calcula de la forma siguiente:

$$M = D = P \mathbf{\Lambda}^{-1} P^T \text{ para } T^2$$

$$M = \tilde{C} = \tilde{P} \tilde{P}^T \text{ para } Q$$

$$M = \Phi = \frac{\tilde{C}}{T_\alpha^2} + \frac{D}{Q_\alpha} \Omega \text{ para } \varphi$$

$\tilde{P}$  es la matriz formada por las últimas  $m-a$  columnas de  $\mathbf{V}$  (matriz de vectores singulares).



e) *Diagramas de contribución modificados*: Este método se basa en encontrar las variables que, después de ser reconstruidas, consiguen las mayores reducciones del estadístico combinado  $\varphi$  hasta que este caiga por debajo de su umbral [4]. Para la variable reconstruida  $i$  la reducción del índice (o estadístico) combinado (RCI) es:

$$c_i^{RCI} = [(x_{nf} - x_{nf}^*)^T (\xi^T \Phi \xi)^{0.5} \xi_i]^2 \quad (10)$$

donde  $x_{nf}$  es el conjunto de variables anómalas y  $x_{nf}^*$  es la reconstrucción de esas variables anómalas:

$$x_{nf}^* = -(\xi^T \Phi \xi)^{-1} \xi^T \Phi (1 - \Gamma) x \quad (11)$$

donde  $\Gamma$  es una matriz diagonal con unos en las posiciones de la diagonal que corresponden con las variables anómalas y ceros en en las posiciones de las variables no anómalas.

La reducción del estadístico combinado después de la reconstrucción se puede calcular así:

$$\varphi - \varphi_{nf}^* = (x_{nf} - x_{nf}^*)^T (\xi^T \Phi \xi) (x_{nf} - x_{nf}^*) \quad (12)$$

Cuando el estadístico combinado cae por debajo de su umbral, las variables contenidas en el conjunto de variables anómalas, con mayores índices de contribución son las consideradas responsables del fallo.

### B. Operadores lingüísticos

Para obtener una diagnosis global y más robusta, se requiere una toma de decisiones considerando las siete técnicas de diagnosis anteriores. Esto se implementa mediante operadores lingüísticos basados en OWA-RIM.

*Operadores OWA*: Los operadores OWA [6] son ampliamente conocidos y empleados, se definen como una función  $F : \mathbb{R}^n \rightarrow \mathbb{R}$  asociada al vector  $\omega$ :

$$\omega = (\omega_1, \omega_2, \omega_3, \dots, \omega_n) \quad (13)$$

donde  $\omega_j \in [0, 1]$  y  $1 \leq j \leq n$ , cumpliéndose, además, que

$$\sum_{j=1}^n \omega_j = 1 \quad (14)$$

Si se dispone de un conjunto de resultados  $\langle \alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n \rangle$  como consecuencia de aplicar metodologías alternativas, y se ordenan de mayor a menor, resultando en  $\langle \beta_1, \beta_2, \beta_3, \dots, \beta_n \rangle$ , siendo  $\beta_1$  el mayor y  $\beta_n$  el menor, el resultado de aplicar el operador OWA es:

$$F(\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n) = \sum_{j=1}^n \omega_j \beta_j \quad (15)$$

En [10] se presentó una forma de determinar los elementos del vector de pesos usando cuantificadores lingüísticos *fuzzy*. El vector  $\omega$  de pesos asociado a un cuantificador  $Q$  se obtiene de la siguiente forma:

$$\omega_j = Q\left(\frac{j}{n}\right) - Q\left(\frac{j-1}{n}\right) \quad (16)$$

con  $j = 1, \dots, n$ .

En [11] se recopilan una serie de cuantificadores lingüísticos del tipo Regular Increasing Monotone (RIM), como las que aparecen en la Tabla I y que son empleados en este trabajo.

Table I  
CUANTIFICADORES LINGÜÍSTICOS RIM

Término lingüístico	Función de pertenencia	Orness
There exists	$Q(x) = \begin{cases} 0 & \text{si } x = 0 \\ 1 & \text{si } x \neq 0 \end{cases}$	1
All	$Q(x) = \begin{cases} 0 & \text{si } x = 1 \\ 1 & \text{si } x \neq 1 \end{cases}$	0
Most (Wang) [12]	$Q(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 0.3 \\ 2(x - 0.3) & \text{si } 0.3 < x \leq 0.8 \\ 1 & \text{si } 0.8 < x \leq 1 \end{cases}$	0.45
At least half	$Q(x) = \begin{cases} 2x & \text{si } 0 \leq x \leq 0.5 \\ 1 & \text{si } 0.5 < x \leq 1 \end{cases}$	0.75
As many as possible	$Q(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 0.5 \\ 2x & \text{si } 0.5 < x \leq 1 \end{cases}$	0.25
Average	$Q(x) = x$ si $0 \leq x \leq 1$	0.5
More than $\alpha$	$Q(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq \alpha \\ \frac{x}{1-\alpha} & \text{si } \alpha < x \leq 1 \end{cases}$	$\frac{1-\alpha}{2}$
At least $\alpha$	$Q(x) = \begin{cases} \frac{x}{\alpha} & \text{si } 0 \leq x \leq \alpha \\ 1 & \text{si } \alpha < x \leq 1 \end{cases}$	$1 - \frac{\alpha}{2}$
Most (Pasi) [13]	$Q(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 0.4 \\ 2(x - 0.4) & \text{si } 0.4 < x \leq 0.9 \\ 1 & \text{si } 0.9 < x \leq 1 \end{cases}$	0.35
Most (Feng) [14]	$Q(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 0.5 \\ (2x - 1)^{0.5} & \text{si } 0.5 < x \leq 1 \end{cases}$	0.33

El comportamiento del operador OWA va de un nivel más alto a un nivel menor de compensación: el operador es más tipo *OR* si no penaliza en exceso la presencia de elementos de bajo valor en la bolsa, y es más tipo *AND* si penaliza más la presencia de esos elementos. [6] propone una forma de clasificarlos según su comportamiento:

$$orness(\omega) = \frac{1}{n-1} \sum_{j=1}^n (n-j)\omega_j \quad (17)$$

El valor del *orness* de un operador puede tomar valores entre 0 y 1. Si es superior a 0.5, el operador es tipo *OR*, pero si es inferior a 0.5 es del tipo *AND*.

### III. DIAGNOSIS DE FALLOS

La metodología de diagnóstico, como ya se ha comentado anteriormente, se basa en la descrita en [5]: la identificación de fallos se realiza en dos instantes de tiempo:  $t_0$ , justo después de la detección, y  $t_1$  una vez que el sistema, en condiciones de funcionamiento defectuoso, ha llegado a un nuevo punto de funcionamiento estacionario. Se buscaba conocer el origen del fallo y, también, ver cómo evoluciona el sistema después de dicho fallo, para saber si es necesario realizar reparaciones, detener el proceso, continuar con él, etc. Por otro lado, también se busca conseguir una diagnosis más robusta aplicando varios métodos de identificación de fallos y alcanzando una diagnosis global. Combinando así las prestaciones de cada método mediante OWA-RIM basado en el cuantificador  $Q(r)$  [15]:

$$Q_\alpha(r) = r^\alpha \quad (18)$$

que proporciona los pesos  $\omega_i$ :

$$\omega_j = \left(\frac{j}{n}\right)^\alpha - \left(\frac{j-1}{n}\right)^\alpha \quad (19)$$

Y su nivel de *orness* es:

$$orness(Q_\alpha) = \frac{1}{1 + \alpha} \quad (20)$$

En este artículo se introducen en la diagnosis propuesta, los cuantificadores descritos en la Tabla I, cuantificadores lingüísticos de fácil introducción en los entornos industriales de mantenimiento. Y los resultados se analizan mediante la conocida distancia de Damerau-Levenshtein [16], [17], entre la secuencia de diagnosis estimada y la conocida.

### IV. CASO DE ESTUDIO: PLANTA DEPURADORA DE AGUAS RESIDUALES

#### A. Depuradora de aguas residuales

La planta Benchmark Simulation Model 2 (BSM2) es un benchmark de amplio uso para estrategias de control en plantas depuradoras de aguas residuales [18]. Implementado en Matlab-Simulink, los datos que proporciona representan el estado del agua residual a la salida de distintos elementos de la red. Se dispone de 20 puntos de medida en los que se miden 7 variables, y, además, se dispone de 13 fallos implementados (más detalles en [5]).

1) *Metodología experimental*: Los parámetros de la diagnosis de fallos son: ventana temporal *Early* de 5 instantes de muestreo, y ventana temporal *Steady* de 5 instantes,  $Th_{Steady} = 0.5$  y  $Var_{Steady} = 0.001$ .

Los cuantificadores lingüísticos a aplicar son los mostrados en la Tabla I. En el caso de '*More than  $\alpha$* ' y '*At least  $\alpha$* ', el parámetro  $\alpha$  tomará los siguientes valores:  $\alpha = \{0.4, 0.5, 0.6\}$ .

La evaluación del desempeño de cada cuantificador lingüístico OWA-RIM, que considera una agregación del resultado de la diagnosis de cada método FI considerado, se ha basado en el porcentaje de acierto en la identificación de las variables responsables del fallo. Para ello se ha analizado el grado de coincidencia entre las variables identificadas como

responsables del fallo por un determinado método con las variables que se saben afectadas por el fallo. Dicho grado de coincidencia se ha medido con la distancia de Damerau-Levenshtein. Los pesos utilizados para calcular esta medida fueron: borrado de elementos: 0.1, introducción de elementos: 0.4, sustitución de elementos: 0.4 y transposición de elementos: 0.1. Es decir, está más penalizado introducir elementos nuevos o sustituirlos que eliminarlos o cambiarlos de posición. Por tanto, los métodos que no hayan encontrado alguna variable responsable estarán muy penalizados, al contrario de los que sí las hayan encontrado. Si la distancia de Damerau-Levenshtein obtenida es 0 implica una identificación perfecta (el método ha identificado todas las variable responsables del fallo, y no ha incluido ninguna más); y cuanto peor sea el resultado de identificación, es decir, no identifica alguna o ninguna de las variables responsables del fallo, mayor será esta distancia.

Cada fallo tiene una serie de variables en las que se origina dicho fallo, en la tabla II se detallan esas variables para cada fallo, así como se da una idea del tipo de fallo, se han considerado cuatro fallos distintos con diferentes magnitudes, dando un total de 13 conjuntos diferentes de datos de fallo. Cada método correspondiente a cada cuantificador, entregará una lista de variables ordenadas según la puntuación obtenida al aplicar OWA, ordenadas de mayor a menor. En algunos fallos, hay una variable responsable del fallo y en otros hay dos (ver tabla II), por tanto, cuando se haga la evaluación del rendimiento de cada cuantificador, se tomarán la primera o las dos primeras variables respectivamente, de la lista de variables entregada por cada método y se medirá la distancia de dichas variables con las realmente responsables del fallo.

Table II  
VARIABLES RESPONSABLES DE LOS FALLOS Y TIPOS DE FALLO

	Fallos 1-5	Fallos 6-8	Fallos 9-11	Fallos 12-13
<b>Variables</b>	42 125	8 15	22	80 86
<b>Tipo de fallo</b>	Sensor de $O_2$	Alcalinidad en el influente	Alcalinidad en el reactor 1	Cambio en los flujos $Q_r$ y $Q_w$

2) *Resultados*: El objetivo es analizar las prestaciones de los cuantificadores para una diagnosis más robusta, por tanto que coincida en la diagnosis conocida en el mayor grado posible. Los resultados de la identificación para la ventana *Early* se muestran en la tabla III.

Los fallos 1 a 5 son los más difíciles de identificar, y ahí es dónde los métodos dan, en general, peor resultado, mientras que en los fallos 6 a 13 la mayoría de métodos obtienen mejores resultados. Las mejores diagnosis (distancias más pequeñas) se han obtenido usando los cuantificadores del tipo '*Most*' (Wang, Pasi y Feng), '*As many as possible*', '*More than 0.4*' y '*More than 0.5*' que tienen valores de *orness* moderadamente bajos (entre 0.25 y 0.45), es decir, requieren que hayan una mayoría de métodos que elijan a las mismas variables como candidatas (aunque no tienen por qué coincidir todos los métodos).



Table III  
DIAGNOSIS VENTANA *Early* BASADA EN LA DISTANCIA DE DAMERAU-LEVENSHTEIN: 0 → DIAGNOSIS PERFECTA.

Fallo	There	All	Most (Wang)	At least half	As many	Average	More than 0.4	More than 0.5	More than 0.6	At least 0.4	At least 0.5	At least 0.6	Most (Pasi)	Most (Feng)
1	0.8	0.8	0	0.8	0	0	0	0	0.3	0.8	0.8	0	0	0
2	0.8	0.8	0	0	0	0	0	0	0.3	0.8	0	0	0	0
3	0.8	0.3	0	0.8	0	0.8	0	0	0	0.8	0.8	0.8	0	0
4	0.8	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4
5	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0.4	0.4	0	0	0	0	0	0	0	0	0	0	0	0
10	0.4	0.4	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0
12	0.3	0	0	0	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Media	<b>0.392</b>	<b>0.3</b>	<b>0.092</b>	<b>0.215</b>	<b>0.092</b>	<b>0.154</b>	<b>0.092</b>	<b>0.092</b>	<b>0.138</b>	<b>0.277</b>	<b>0.215</b>	<b>0.1538</b>	<b>0.092</b>	<b>0.092</b>

Por contra, los métodos '*At least 0.4*', '*At least 0.5*' y '*At least half*' con un *orness* entre 0.8 y 0.75, tienen unas de las puntuaciones peores de la comparativa, siendo los métodos con *orness* extremos (0 y 1), como '*There exists*' y '*All*', los que dan un peor resultado.

Los métodos con *orness* entre 0.5 y 0.7 como son '*Average*' y '*At least 0.6*' consiguen resultados buenos, pero sin llegar a los de los mejores. A su vez, el método '*More than 0.6*', con un *orness* de 0.2 también consigue un resultado aceptable.

Viendo estos resultados se puede concluir que la mayoría de los métodos de FI que se han usado dan un buen resultado en la diagnosis temprana, es decir diagnosticar el fallo justo en el momento en que se detecta el fallo. La agregación de todos los métodos FI da una diagnosis más correcta y robusta, sobre todo usando métodos OWA con cuantificadores que tienen valores *orness* bajos, en cuyo caso la distancia es cero, es decir, diagnostican siempre las variables responsables del fallo.

Los resultados de la identificación para la ventana *Steady* se muestran en la tabla IV. En este caso, los resultados se han igualado bastante entre los métodos. En los fallos 1 al 5 y 9 al 11, el fallo se propaga por varias zonas de la planta y es más complejo encontrar las variables causantes del fallo. El cuantificador '*There*' sigue siendo el peor método, y el resto han dado resultados muy similares, siendo '*All*' el mejor, seguido a poca distancia por '*More than 0.4*', '*More than 0.5*' y '*More than 0.6*'. En cualquier caso, en esta ventana de identificación no se aprecian grandes diferencias entre usar un cuantificador u otro.

Estos resultados demuestran, que cada método de FI usado identifica variables diferentes como responsables del fallo, ya que ahora hay muchas variables afectadas por el fallo además de las que lo originaron. Por lo que diagnosticar fallos sólo en el estacionario después del fallo como hacen varios autores no es adecuado en todos los tipos de fallos, ya que la diagnosis calculada no es la correcta.

3) *Ejemplo: fallo 2*: Se muestran en la tabla V, como ejemplo, los resultados del fallo 2 (fallo en un sensor de  $O_2$ ) obtenidos por cada uno de los métodos, en la que se muestran las puntuaciones para la ventana *Early*, obtenidas con cada método para las 6 primeras variables del ranking.

Los métodos '*There*' y '*At least 0.4*' no consiguen encontrar las variables responsables del fallo. Por contra, los métodos '*Most (Wang)*', '*At least half*', '*As many as possible*', '*Average*', '*More than 0.4*', '*More than 0.5*', '*At least 0.5*', '*At least 0.6*', '*Most (Pasi)*' y '*Most (Feng)*' han identificado las dos variables responsables del fallo lo que les permite obtener una distancia de 0 (identificación perfecta), como se ve en la tabla III. '*More than 0.6*' tiene una variable responsable en la primera posición, pero la segunda no es una de las responsables, por tanto, su distancia es de 0.3 (tabla III). El método '*All*' no identifica ninguna variable como responsable del fallo ya que sus contribuciones son todas cero.

En la tabla VI se muestran los resultados para el fallo 2 con la ventana *Steady*. En este caso, las puntuaciones OWA son similares entre las variables, lo que indica la expansión del fallo por la planta. '*All*' es el único método capaz de identificar a una de las variables responsables del fallo, el resto no tienen dichas variables en las dos primeras posiciones, por tanto, obtienen una peor distancia (ver tabla IV).

## V. CONCLUSIONES

En este artículo se ha realizado una comparativa entre diferentes variantes de un método de identificación de fallos multi-método cuando se introducen nuevos cuantificadores lingüísticos. Cada método de diagnosis realiza un identificación, y se obtiene una diagnosis global agregando la solución de cada método FI, utilizando operadores OWA-RIM con diferentes cuantificadores lingüísticos, comprobando el nivel de robustez de la identificación obtenida con cada cuantificador estudiado.

Los resultados muestran que los cuantificadores con valores de *orness* comprendidos entre 0.3 y 0.5 son los que mejor funcionan en la identificación inmediatamente posterior a la detección del fallo. Además estos métodos dan una diagnosis correcta, ya que la distancia calculada es cero. Mientras, en la identificación que se realiza cuando el sistema llega a un estado estacionario al evolucionar después del fallo, los resultados se igualan para todos los cuantificadores y dan peores resultados.

Como trabajo futuro, necesario para mejorar los resultados de la identificación en la ventana estacionaria, consistirá en



Table IV  
DIAGNOSIS VENTANA *Steady* BASADA EN LA DISTANCIA DE DAMERAU-LEVENSHEIN: 0 → DIAGNOSIS PERFECTA.

Fallo	There	All	Most (Wang)	At least half	As many	Average	More than 0.4	More than 0.5	More than 0.6	At least 0.4	At least 0.5	At least 0.6	Most (Pasi)	Most (Feng)
1	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
2	0.8	0.3	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
3	0.8	0.3	0.8	0.8	0.8	0.8	0	0	0	0.8	0.8	0.8	0.8	0.8
4	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
5	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4
10	0.4	0.4	0	0.4	0.4	0	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0
11	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4
15	0.3	0	0	0	0	0	0	0	0	0	0	0	0	0
16	0.3	0	0	0	0	0	0	0	0	0	0	0	0	0
<b>Media</b>	<b>0.446</b>	<b>0.323</b>	<b>0.369</b>	<b>0.4</b>	<b>0.4</b>	<b>0.369</b>	<b>0.338</b>	<b>0.338</b>	<b>0.338</b>	<b>0.4</b>	<b>0.4</b>	<b>0.4</b>	<b>0.4</b>	<b>0.369</b>

Table V  
RESULTADOS DE CADA CUANTIFICADOR. FALLO 2 VENTANA *Early*

Método	Variables	Puntuaciones
There	62 69 76 83 56 55	0.88 088 0.84 0.84 0.84 0.81
All	1 2 3 4 5 6	0 0 0 0 0 0
Most (Wang)	42 125 49 86 82 21	0.35 0.26 0.22 0.088 0.07 0.07
At least half	42 125 55 59 79 7	0.48 0.48 0.47 0.46 0.45 0.43
As many	42 125 49 86 21 82	0.6 0.52 0.38 0.13 0.11 0.1
Average	42 125 55 49 59 79	0.33 0.28 0.24 0.23 0.23 0.23
More than 0.4	42 125 49 86 82 20	0.51 0.43 0.33 0.16 0.13 0.12
More than 0.5	42 125 49 86 21 82	0.61 0.52 0.38 0.13 0.11 0.1
More than 0.6	42 49 125 86 21 82	0.69 0.36 0.16 0.11 0.1 0.09
At least 0.4	55 59 79 7 14 62	0.58 0.57 0.56 0.52 0.52 0.5
At least 0.5	42 125 55 59 79 7	0.48 0.48 0.47 0.46 0.45 0.43
At least 0.6	42 125 55 59 79 7	0.46 0.45 0.4 0.38 0.38 0.37
Most (Pasi)	42 125 49 86 82 21	0.27 0.18 0.16 0.06 0.05 0.05
Most (Feng)	42 125 49 86 21 82	0.27 0.19 0.17 0.05 0.05 0.04

Table VI  
RESULTADOS DE CADA CUANTIFICADOR. FALLO 2. VENTANA *Steady*

Método	Variables	Puntuaciones
There	19 12 5 123 94 100	0.91 0.91 0.89 0.89 0.89 0.89
All	125 1 2 3 4 5	0.04 0 0 0 0 0
Most (Wang)	62 69 56 125 49 42	0.79 0.56 0.49 0.49 0.49 0.37
At least half	61 68 50 42 125 43	0.64 0.58 0.47 0.47 0.47 0.42
As many	61 68 50 42 125 43	0.64 0.58 0.47 0.47 0.47 0.42
Average	62 69 42 56 125 49	0.69 0.56 0.49 0.49 0.49 0.4
More than 0.4	62 69 56 42 125 49	0.68 0.55 0.49 0.49 0.47 0.45
More than 0.5	62 69 56 42 125 49	0.69 0.56 0.49 0.49 0.49 0.4
More than 0.6	62 69 56 42 125 49	0.7 0.58 0.49 0.49 0.47 0.39
At least 0.4	121 97 103 109 115 114	0.61 0.61 0.61 0.61 0.61 0.61
At least 0.5	61 68 50 42 125 43	0.64 0.58 0.47 0.47 0.47 0.41
At least 0.6	61 68 42 125 50 43	0.58 0.53 0.45 0.45 0.4 0.34
Most (Pasi)	62 69 56 49 42 125	0.64 0.39 0.35 0.35 0.35 0.27
Most (Feng)	62 69 56 49 42 125	0.64 0.41 0.36 0.36 0.36 0.28

estudiar la distancia de Damerau-Levenshtein con cadenas de tamaño diferente, o introduciendo el valor de las contribuciones de cada variable en el cálculo de la distancia, no sólo su posición.

REFERENCES

[1] T. Kourti and J. MacGregor, "Multivariate SPC methods for process and product monitoring," *Journal of Quality Technology*, vol. 28, pp.

409-428, 1996.  
 [2] H. Yue and S. J. Qin, "Reconstruction based fault identification, using a combined index," *Industrial & Engineering Chemistry Research*, vol. 40(20), pp. 4403-4414, 2001.  
 [3] C. F. Alcalá and S. J. Qin, "Reconstruction-based contribution for process monitoring," *Automatica*, vol. 45, pp. 1593-1600, 2009.  
 [4] J. Liu and D.-S. Chen, "Fault isolation using modified contribution plots," *Computers & Chemical Engineering*, vol. 61, pp. 9-19, 2014.  
 [5] A. Sánchez-Fernández, G. Sainz-Palmero, J. Benítez, and M. Fuente, "Linguistic OWA and two time-windows based fault identification in wide plants," *Computers & Chemical Engineering*, vol. 115, pp. 412-430, jul 2018.  
 [6] R.R. Yager, "On ordered weighted averaging aggregation operators in multi-criteria decision making," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 18, pp. 183-190, 1988.  
 [7] R. Dunia and S. J. Qin, "Subspace approach to multidimensional fault identification and reconstruction," *AIChE Journal*, vol. 44, pp. 1813-1831, 1998.  
 [8] J. E. Jackson, *A user's guide to principal components*. Wiley, 1991.  
 [9] P. Nomikos and J. F. MacGregor, "Multivariate SPC charts for monitoring batch processes," *Technometrics*, vol. 37, no. 1, pp. 41-59, 1995. [Online]. Available: <https://www.tandfonline.com/doi/abs/10.1080/00401706.1995.10485888>  
 [10] R. Yager, "Quantifier guided aggregation using OWA operators," *International Journal of Intelligent Systems*, vol. 11, pp. 49-73, 1996.  
 [11] X. Liu and S. Han, "Orness and parameterized rim quantifier aggregation with owa operators: A summary," *International Journal of Approximate Reasoning*, vol. 48, no. 1, pp. 77-97, apr 2008, special Section: Perception Based Data Mining and Decision Support Systems. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0888613X07000709>  
 [12] J. Wang and Y.-I. Lin, "A fuzzy multicriteria group decision making approach to select configuration items for software development," *Fuzzy Sets and Systems*, vol. 134, no. 3, pp. 343-363, 2003. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S016501140200283X>  
 [13] R. Pasi and R. R. Yager, "Modeling the concept of majority opinion in group decision making," *Information Sciences*, vol. 176, no. 4, pp. 390-414, 2006, recent advancements of fuzzy sets: theory and practice. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0020025505002227>  
 [14] L. Feng and T. Dillon, "Using fuzzy linguistic representations to provide explanatory semantics for data warehouses," *IEEE Transactions on Knowledge and Data Engineering*, vol. 15, no. 1, pp. 86-102, jan 2003.  
 [15] R. Yager, "Families of OWA operators," *Fuzzy Sets and Systems*, vol. 59, pp. 125-148, 1993.  
 [16] F. J. Damerau, "A technique for computer detection and correction of spelling errors," *Commun. ACM*, vol. 7, no. 3, pp. 171-176, Mar. 1964. [Online]. Available: <http://doi.acm.org/10.1145/363958.363994>  
 [17] V. I. Levenshtein, "Binary codes capable of correcting deletions, insertions and reversals," *Soviet Physics Doklady*, vol. 10, p. 707, 1966.  
 [18] J. Alex, L. Benedetti, J. Copp, K. Gernaey, U. Jeppsson, I. Nopens, M. Pons, C. Rosen, J. Steyer, and P. Vanrolleghem, "Benchmark simulation model no. 2," 2008.



# Interoperabilidad de flujos de trabajo intensivos en datos en Industria 4.0: caso de estudio

Rubén Salado-Cid, José Molino, José Raúl Romero  
Dpto. de Informática y Análisis Numérico, Universidad de Córdoba  
{rsalado, i32moorj, jrromero}@uco.es

**Resumen**—Con la transformación digital del sector industrial propuesta por la Industria 4.0, se ha producido un gran incremento del volumen de datos gestionado por las empresas, situando así a la ciencia de datos como un pilar tecnológico fundamental. La complejidad en el uso de las técnicas computacionales ha promovido el desarrollo de herramientas basadas en flujos de trabajo intensivos en datos para definir el conocimiento del experto a un alto nivel de abstracción, ocultando los detalles de computación a bajo nivel. Sin embargo, la falta de estándares imposibilita la reutilización de este conocimiento, lo que obliga al aprendizaje de varias herramientas, según los requisitos de cada dominio, o bien a quedar limitados por las características de una de ellas. En este trabajo se presenta una propuesta para la interoperabilidad de flujos intensivos en datos mediante la implementación de una serie de transformaciones y su automatización accesible a través de servicios web. Para ello, se analiza detalladamente cada sistema, así como los elementos que definen sus flujos, antes de declarar las equivalencias. Después se ilustra la propuesta con un caso de estudio de un flujo industrial, definido en Taverna, y la obtención de su equivalente en Kepler.

**Index Terms**—flujos de trabajo intensivos en datos, ciencia de datos, interoperabilidad

## I. INTRODUCCIÓN

La transformación digital que se está llevando a cabo en todos los sectores industriales está cambiando la forma en la que las empresas operan, teniendo que adaptar sus entornos de producción a un nuevo paradigma industrial, conocido como Industria 4.0. La Industria 4.0 tiene como base la utilización masiva de sensores, dispositivos y de sistemas de información con el fin de mejorar y optimizar los productos y métodos productivos, mediante el procesamiento de grandes cantidades de datos. De hecho, los datos ocupan un lugar principal en esta nueva revolución industrial y sitúan a la ciencia de datos [1] como un pilar tecnológico sobre el que se sustenta este nuevo paradigma.

Ciertamente, la ciencia de datos proporciona un gran número de herramientas y técnicas computacionales [2], [3] que permiten procesar y analizar enormes cantidades de datos, lo que resultaba inalcanzable con las técnicas tradicionales de procesamiento de datos. Sin embargo, la complejidad inherente a este tipo de tecnologías hace necesario el uso de propuestas que faciliten la representación del conocimiento capturado por los procesos computacionales intensivos en datos y permitan

la automatización de su ejecución. Esto es, se debe permitir definir *qué* se quiere hacer independientemente del *cómo*.

Para lograr este propósito surgen los sistemas de gestión de flujos de trabajo (WfMS, *workflow management systems*) [5]. Un flujo de trabajo [4] permite capturar y modelar el conocimiento del experto como una secuencia de acciones o tareas que trabajan en coordinación para llevar a cabo un objetivo determinado. Esta secuencia de acciones es definida a un alto nivel de abstracción, más cercano al dominio del experto, haciendo transparentes los aspectos de bajo nivel de computación. Los WfMS ya se utilizan en numerosos ámbitos industriales como pueden ser la manufacturación [6], ventas on-line (*retail*) [7] o telecomunicaciones [8]. Sin embargo, ninguno de estos sistemas formaliza la manera en que los flujos de trabajo son representados, siendo cada representación propia de la herramienta. Esto conlleva la imposibilidad de reutilizar el conocimiento como activo e incluso limita la expresividad y alcance del mismo, según las funcionalidades y operaciones propias del WfMS. Así, distintos WfMS frecuentemente se especializan en dominios concretos, por lo que existe la necesidad de desarrollar mecanismos de interoperabilidad entre distintos flujos intensivos en datos [9].

Recientemente se propuso un lenguaje común para la definición de flujos de trabajo intensivos en datos [10], si bien se encuentra en un estado muy inicial y no hay soporte. Por ello, con el objetivo de promover la reutilización del conocimiento y operaciones de extracción del mismo sobre datos industriales, sería necesario poder ofrecer interoperabilidad sin requerir la adaptación de las herramientas existentes o de los flujos de trabajo ya definidos, algo poco realista en los tiempos que maneja la industria.

Por ello, en este trabajo se discute una primera propuesta para alcanzar la interoperabilidad entre distintos flujos de trabajo intensivos en datos ya existentes. En primer lugar se ha realizado un estudio de las características proporcionadas por las principales herramientas basadas en flujos de datos. Este estudio permite identificar los elementos más importantes en la definición de los flujos de trabajo de cada WfMS, detectar cuáles son comunes y cuáles exclusivos, así como conocer la forma en la que estos se representan. A partir de este estudio se formaliza la manera en que las herramientas actuales expresan esos elementos con el fin de implementar una serie de transformaciones entre ellos. Para este propósito, se utiliza un lenguaje intermedio, presentado en [12], independiente de cualquier WfMS. Dicha formalización y sus transformaciones

Este trabajo ha sido cofinanciado por el Ministerio de Economía y Competencia del Gobierno de España [proyecto TIN2017-83445-P]

se lleva a cabo de forma transparente en una capa inferior utilizando *ingeniería dirigida por modelos* [11]. Se omitirán los detalles más específicos por situarse fuera del ámbito de este trabajo y por motivos de espacio, si bien, esta capa habilitará la aplicación de las técnicas de ciencias de datos sobre un mayor abanico de áreas de la Industria 4.0. Finalmente, se propone un prototipo de servicio web como demostración de la solución propuesta. Este servicio puede ser integrado en herramientas externas a través de su API REST.

La propuesta se ilustra mediante un caso de estudio en el que un flujo de trabajo intensivo en datos aplicado a Industria 4.0, que ha sido definido en una herramienta específica, es transformado a otro flujo de trabajo equivalente y compatible con otro WfMS distinto pero manteniendo los elementos de conocimiento (procesos y artefactos) originales.

En el resto del artículo se organiza como sigue. En la Sección II se introducen los sistemas de gestión de flujos de trabajo y se destacan algunos de los más relevantes actualmente. En la Sección III se analizan las características más destacadas para representar los flujos de trabajo. A continuación, en la Sección IV se detalla la propuesta para alcanzar la interoperabilidad, cuya demostración es realizada en la Sección V. Finalmente, los resultados obtenidos son discutidos en la Sección VI, y se presentan las conclusiones y líneas de trabajo futuro en la Sección VII.

## II. ESTADO DEL ARTE

Los sistemas de gestión de flujos de trabajo son herramientas que permiten la definición y gestión de la ejecución del conjunto de tareas que conforman un proceso computacional, junto con sus dependencias. Para ello, habitualmente estos sistemas proporcionan un editor gráfico que permite la representación visual a alto nivel de los flujos de trabajo. Estos flujos suelen organizarse como un grafo, donde una serie de nodos o componentes son interconectados para definir el orden de ejecución según la lógica de negocio. Una vez definido, la ejecución es gestionada por uno o más motores de ejecución especializados que gestionan los recursos computacionales disponibles e invocan automáticamente las tareas computacionales definidas de forma óptima y transparente.

Actualmente existen una gran variedad de WfMS utilizados en ciencia de datos. Uno de las más destacadas es KNIME [13], de código libre, que proporciona acceso a un gran número de algoritmos configurables para la integración, transformación y visualización de datos. KNIME se utiliza satisfactoriamente en banca, industria o en investigación y desarrollo, entre otros dominios. Otra herramienta muy similar es RapidMiner [14] que proporciona una serie de procesos de minería de datos y de aprendizaje automático para permitir la carga, transformación, preprocesamiento y visualización de datos. Por citar algunos ejemplos, RapidMiner se ha aplicado a la optimización de procesos computacionales en marketing y en gestión política, o a la mejora en cadenas de producción.

Existen otros WfMS más orientados a la aplicación de procesos de ciencia de datos, y que, hasta el momento, se han venido utilizando en dominios de carácter más científico.

Taverna [15] es una herramienta que proporciona los recursos necesarios para definir y ejecutar flujos de trabajo con el fin de aceptar o rechazar hipótesis científicas. Por ello, es un WfMS utilizado en un gran rango de dominios, como la industria biomédica y la informática química. Asimismo, Kepler [16] es otro WfMS que ofrece una gran cantidad de algoritmos para el procesamiento de datos, desde su carga hasta la transformación y visualización de los mismos. Kepler ha sido utilizado en dominios como la bioinformática. Si bien el tipo de industria que aplica estas herramientas es de carácter experimental, no existe limitación alguna que impida su uso en otros dominios intensivos en datos, incluyendo los propios de la Industria 4.0.

Como se indicaba anteriormente, la falta de estandarización en este tipo de tecnologías intensivas en datos hace que las características de cada herramienta puedan ser o no compatibles con las demás, provocando una pérdida notable de elementos de conocimiento y procedimientos ya estructurados debido a la imposibilidad de su reutilización.

## III. ANÁLISIS DE LAS REPRESENTACIONES DE LOS FLUJOS DE TRABAJO

La Tabla I muestra un resumen de las principales características analizadas en los principales WfMS, como son KNIME, RapidMiner, Taverna y Kepler. Estas propiedades se han agrupado en categorías según su funcionalidad: (a) todas las características referidas a la composición y estructuración de un proceso computacional como *flujo de trabajo*; (b) los distintos aspectos que definen los procesos de extracción de conocimiento que pueden llevarse a cabo en los *nodos de ejecución*; (c) el tipo de *metainformación* descriptiva asociada a los mismos; y (d) las características referidas al almacenamiento y gestión de datos del flujo de trabajo (*serialización*).

Las características relacionadas con la composición de un *flujo de trabajo* permiten conocer su capacidad de configuración y adaptación a distintos dominios. Sería deseable en términos de tiempo y coste que un proceso genérico de ciencia de datos pudiera ser utilizado en diferentes dominios industriales. Así, todas las herramientas analizadas estructuran sus flujos de trabajo como grafos dirigidos, cuyos nodos representan tareas a ejecutar y las conexiones dependencias de datos entre ellos, es decir, cuando un nodo depende de los datos generados por otros nodos para poder ejecutarse. No obstante, eventualmente un nodo podría depender únicamente de la ejecución previa de otros nodos (flujo de control) o del cumplimiento de determinadas condiciones que pueden ser definidas mediante una serie de estructuras de control.

Por otro lado, los nodos definen el comportamiento de las operaciones de procesamiento. Este comportamiento viene determinado por una serie de parámetros que permiten su adaptación al dominio. Toda esta parametrización puede venir preestablecida por el WfMS, así como la apariencia de los distintos elementos, con el objetivo de centrarse en la definición del proceso de extracción. Igualmente, los usuarios pueden modificar la apariencia de los nodos para favorecer la interpretabilidad del flujo por los distintos agentes involucrados.



	KNIME	RAPIDMINER	TAVERNA	KEPLER
Flujo de trabajo				
Estructura	Grafo dirigido	Grafo dirigido	Grafo dirigido	Grafo dirigido
Flujo de datos	Sí	Sí	Sí	Sí
Flujo de control	Sí	Sí	Sí	Sí
Estructuras de control	Condición, bucle, switch	Condición, bucle	Condición, bucle	Condición, bucle, switch
Configuración de nodos	Sí	Sí	Sí	Sí
Configuración de apariencia	Sí	Sí	No	Sí
Parámetros por defecto	Sí	Sí	No	Sí
Nodos de ejecución				
Tipos de datos	Básicos, complejos	Básicos, complejos	Básicos	Básicos, complejos
Fuentes de datos	Memoria, fichero, base de datos	Memoria, fichero, base de datos	Memoria	Memoria, fichero, base de datos
Tareas	Java, JavaScript	Java, Groovy	Java, R	Java, R, Python, Matlab, Groovy, JavaScript
Invocación de servicios	REST	REST	SOAP	REST, SOAP
Flujos de trabajo anidados	No	Sí	Sí	Sí
Metainformación				
Descripción de nodos	Sí	No	No	No
Contexto	Sí	Sí	Sí	Sí
Serialización				
Formato	XML	XML	XML	XML
Estructura	Múltiples ficheros y directorios	Único fichero	Único fichero	Único fichero
Accesible	Sí	Sí	Sí	Sí
Compresión	No	No	No	No

Tabla I

RESUMEN DE CARACTERÍSTICAS DE LOS PRINCIPALES WfMS

En aquellos procesos en los que se deben aplicar procedimientos computacionales costosos sobre datos bien digitalizados o directamente procedentes de sistemas industriales (p.ej. sistemas de manufactura industrial, sensores, etc.), los *nodos de ejecución* definen cómo estos datos serán transformados para generar otros nuevos que, a su vez, sean consumidos por otros nodos hasta extraer conocimiento de ello. Cada herramienta define los tipos de datos específicos que pueden ser manipulados, desde tipos básicos (cadenas, numéricos, booleanos, etc.) hasta tipos complejos (secuencias, imágenes, estructuras complejas procedentes de sistemas externos, etc.). Igualmente, estos datos pueden proceder de distintas fuentes.

Existen distintos tipos nodos de ejecución que pueden ser representados por los flujos de trabajo. Por una parte, las tareas son operaciones cuya ejecución viene determinada por un algoritmo en algún lenguaje de programación. Por otra parte, es habitual encontrar nodos que permiten la invocación remota

de servicios web, permitiendo la conexión entre sistemas remotos, por ejemplo, con otros sistemas industriales o con proveedores externos. En ocasiones, la ejecución es definida por el anidamiento de flujos de trabajo. Esta característica, además de incrementar el nivel de abstracción de los procesos, es un potente mecanismo de reutilización de conocimiento y *know-how* dentro de la propia organización.

Respecto a la *metainformación*, ésta no altera la operación del WfMS, si bien favorece establecer buenas prácticas que faciliten la transferencia del *know-how*, por ejemplo, en equipos con elevada rotación o en la incorporación de nuevos miembros a la organización que deban adquirir destrezas respecto a la organización de los métodos productivos y el procesamiento de sus datos. En general, esta metainformación está relacionada con la descripción del funcionamiento de un nodo específico, del autor o del proyecto.

Finalmente, en términos de interoperabilidad es crítico establecer mecanismos estándares para la *serialización* de los flujos de trabajo. Es habitual que los WfMS utilicen XML, definiendo esquemas propios, para almacenar la estructura y comportamiento de los flujos de trabajo intensivos en datos. La distribución de estos ficheros, su accesibilidad y codificación varía de una herramienta a otra.

#### IV. IMPLEMENTACIÓN DE LOS MECANISMOS DE INTEROPERABILIDAD

El análisis de las características de los distintos WfMS (véase Sección III) establece las bases para el desarrollo de las transformaciones que permitan reconvertir los elementos de flujos de trabajo de un sistema en sus equivalentes dentro de la especificación de otro WfMS, deseablemente de forma bidireccional. Esta transformación debe realizarse de manera automática y transparente al experto de negocio, permitiendo reutilizar activos de conocimiento previamente producidos.

##### IV-A. Implementación de las transformaciones

Para permitir la transformación multisistema, se hace uso de un lenguaje específico del dominio de la ciencia de datos, independiente de cualquier WfMS. Este lenguaje está bien definido y formalizado [12], proporcionando una declaración precisa de cada uno de los elementos que componen un proceso computacional intensivo en datos. Su uso permite reducir drásticamente el número de conversiones necesarias, implementando únicamente las equivalencias del formato de un WfMS *A* al lenguaje específico de dominio intermedio, y viceversa, de un WfMS *B* a este lenguaje, y viceversa, y así sucesivamente. En caso de no utilizar tal lenguaje intermedio, la interoperabilidad debería estudiarse por cada par de WfMS. Así, cada vez que un nuevo proceso o artefacto hubiera sido definido en un WfMS *C* diferente a los ya incorporados, se haría necesario estudiar sus equivalencias par a par con cada uno, creciendo exponencialmente el tiempo y coste requeridos. De este modo, en cambio, el esfuerzo se mantiene constante, independientemente de la variedad de tipos de flujos.

La Figura 1 ilustra la propuesta haciendo uso de un lenguaje específico de dominio intermediario como elemento central.

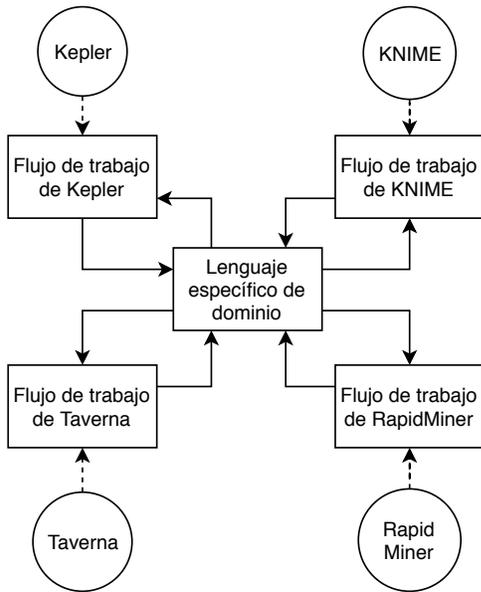


Figura 1. Propuesta para alcanzar la interoperabilidad entre distintos WfMS

Cada círculo representa un WfMS distinto, sobre el que se definen procedimientos propios para la extracción de conocimiento a partir de los datos generados en la organización o proveídos por terceros. Las flechas continuas indican la dirección de la equivalencia entre elementos de los flujos.

Como se indicara en la Sección I, la transformación de estos elementos no resulta trivial, y requiere una definición precisa de todos ellos, así como la declaración procedimental de las equivalencias en lenguajes de programación específicos para este fin, como ATL<sup>1</sup>. A modo ilustrativo, el código mostrado en el Listado 1 muestra un ejemplo de la transformación de un elemento de un flujo de trabajo de Taverna al lenguaje intermedio. En concreto, una conexión de datos, denominada en este sistema *DataLink*, es convertida a una conexión equivalente (elemento *DataLine*), conservando la referencia a los nodos interconectados.

Listado 1. Transformación de un elemento de Taverna al lenguaje intermedio

```
rule DataLinkToDataLine {
  from
    source : Taverna!DataLink
  to
    targetDataLine : DSL!DataLine
      (targetConnector <- LinkerIn ,
       sourceConnector <- LinkerOut),
    LinkerOut : DSL!Linker
      (endpoint <- source.source),
    LinkerIn : DSL!Linker
      (endpoint <- source.sink) }
```

Finalmente, una vez se obtiene la especificación del procedimiento intensivo en datos en términos del lenguaje intermedio, éste se puede convertir indistintamente a cualquiera de los otros sistemas de flujos de trabajo, evitando la posible pérdida

<sup>1</sup>Más información en <http://www.eclipse.org/atl/>

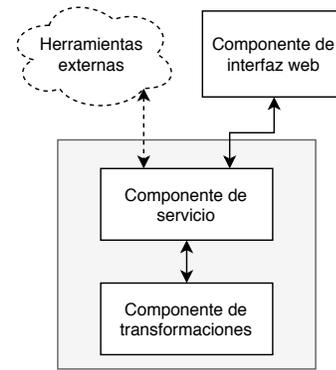


Figura 2. Componentes del prototipo

de *know-how*. Para ello, lenguajes como XSLT o herramientas como *Acceleo*<sup>2</sup> resultan de gran interés para la serialización.

#### IV-B. Interoperabilidad como servicio: Prototipo

A modo de prueba de concepto, se ha desarrollado un prototipo que permite que las conversiones implementadas puedan ser fácilmente utilizadas por cualquier organización o integradas en un sistema externo mediante el uso de una API REST. Este prototipo se divide en tres componentes fundamentales (véase la Figura 2):

- El *componente de transformaciones* realiza las conversiones entre distintos flujos de trabajo (véase Sección IV-A).
- El *componente de servicio* ofrece la funcionalidad del componente de transformaciones a través de una API REST y coreografía todas las operaciones invocadas.
- El *componente de interfaz web* ofrece la página que da acceso al componente de servicio, facilitando la serialización de un flujo de trabajo origen en un formato destino requerido por el usuario.

Como se verá en la Sección V (Figura 4), la interacción con el prototipo se divide en dos zonas. A la izquierda se muestra un cuadro donde se introduce la serialización del flujo de trabajo origen, indicando a qué WfMS se corresponde. A la derecha se encuentra el selector de la herramienta destino. El listado de sistemas de gestión de flujos de trabajo es configurable y flexible, dependiendo de las conversiones que hayan sido definidas respecto al lenguaje específico de dominio intermedio. Al invocar el proceso de transformación, el componente de interfaz web se comunica con el de servicio, que informa a su vez al componente de transformaciones, encargado de devolver el resultado.

#### V. CASO DE ESTUDIO: INTEROPERABILIDAD TAVERNA-KEPLER

Como caso de estudio se ha desarrollado un proceso partiendo de un flujo de trabajo de Taverna. Luego, éste es transformado a un flujo equivalente y compatible con Kepler. Inicialmente se han contemplado los elementos involucrados en la estructuración y composición del proceso, si bien otros

<sup>2</sup>Más información en <http://www.eclipse.org/acceleo>

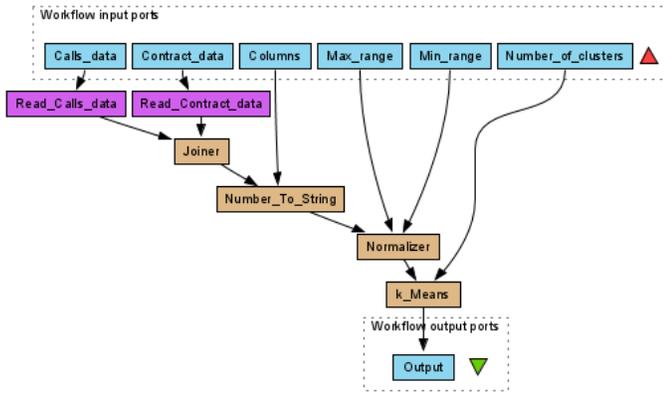


Figura 3. Flujo de trabajo origen en Taverna

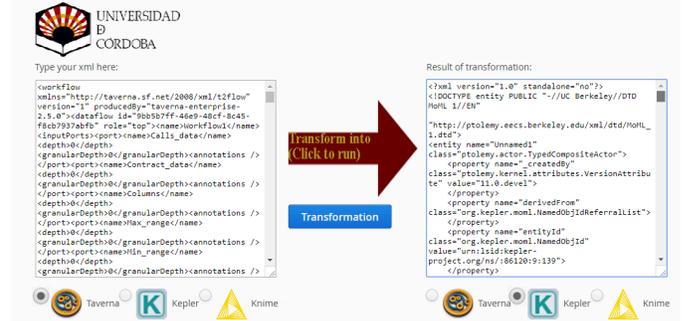


Figura 4. Uso del prototipo para transformar un flujo de trabajo

aspectos más avanzados relacionados con la ejecución se omiten hasta una fase posterior del desarrollo de esta propuesta.

Se analizará un proceso de segmentación de clientes de una empresa de telecomunicaciones como ejemplo de caso de ciencia de datos focalizado a Industria 4.0. La segmentación de clientes consiste en la agrupación de éstos en subgrupos, denominados *segmentos*, que presentan características comunes de consumo. Debido a estas similitudes, es más probable que los clientes de un mismo segmento respondan de modo parecido a estrategias de marketing para un producto. Igualmente, los clientes de distintos segmentos se diferencian de los del resto de subgrupos, por lo que requieren estrategias de marketing diferenciadas. Así pues, la segmentación permite determinar los rasgos básicos y generales que tendrá el potencial consumidor de un producto, aumentando la eficacia de las estrategias.

La Figura 3 representa el flujo de trabajo de Taverna que define el proceso que realiza el análisis de la información relacionada con los hábitos de consumo (p.ej. número de minutos hablados por día o número total de llamadas) y los contratos de los clientes con su compañía telefónica (p.ej. tipo de plan contratado o su código postal). Esta información es leída de dos ficheros, *Calls\_data* y *Contract\_data*, respectivamente. A continuación se lleva a cabo una secuencia de preprocesamiento consistente en operaciones de agregación, *Joiner*, conversión de tipos, *Number\_To\_String*, y normalización de datos, *Normalizer*. Finalmente, se aplica un algoritmo de agrupamiento, k-means, para crear los distintos segmentos que serán utilizados en labores de marketing.

Este flujo de trabajo de Taverna presenta una serie de elementos comunes, estudiados previamente en la Sección III, como son (a) los *tipos de datos básicos*, tanto cadenas como numéricos, (b) los nodos de entrada (*fuentes de datos*) y salida en memoria y de fichero, (c) los *nodos de ejecución* que permiten ejecutar fragmentos de código Java, (d) las *conexiones de datos* y, finalmente, (e) la *serialización* realizada en un único fichero accesible, en formato XML y sin compresión. El WfMS Kepler da soporte a estos mismos elementos, por lo que se pueden establecer correspondencias directas, a excepción de los nodos de ejecución, que son implementados y configurados de forma notoriamente distinta por ambas herramientas.

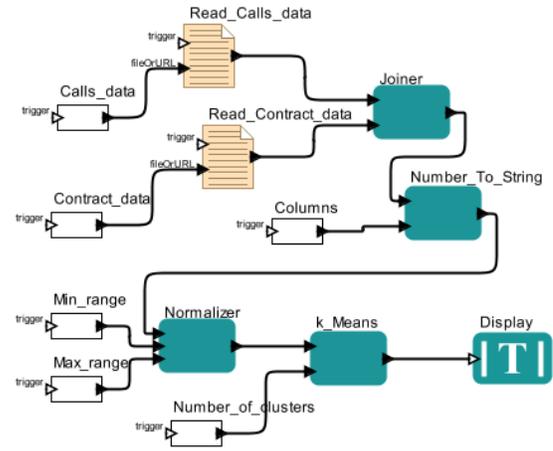


Figura 5. Flujo de trabajo destino en Kepler (generado automáticamente)

Nótese que este tipo de incompatibilidades son comunes y son causa del aumento de la complejidad de la interoperabilidad.

Para llevar a cabo la conversión de activos entre ambos sistemas, primero debe identificarse el modo en que cada uno de los elementos del flujo de Taverna se serializa en XML. Una vez obtenidas todas las descripciones, se aplican las transformaciones (véase Sección IV-A) sobre cada elemento del flujo, obteniendo descripciones precisas compatibles con la formalización del lenguaje intermedio. Obsérvese que, en este punto, los activos definidos sobre el WfMS origen son independientes del sistema destino que los reincorporará, si bien en este estudio se ha trabajado sobre flujos de Kepler. La correspondiente serialización XML para Kepler se genera utilizando la definición formal obtenida para esta herramienta a partir de las conversiones realizadas desde el lenguaje intermedio. Todo este ciclo de conversión es coordinado y realizado de forma automática por el prototipo desarrollado (véase la Figura 4). Como resultado, la Figura 5 muestra el flujo de trabajo destino, que incluye la definición de todos los activos (procesos y artefactos) extraídos a partir de su descripción en Taverna.

## VI. DISCUSIÓN

La interoperabilidad alcanzada permite que el *know-how* organizacional contenido en un flujo de trabajo representado

para un WfMS particular sea reutilizable e independiente de cualquier otro sistema. Con ello, la propuesta establece un mecanismo de intercambio de activos entre herramientas distintas e incompatibles, siendo éste además de escalabilidad lineal con respecto a la incorporación de nuevos WfMS. El interés de la industria en conseguir activos interoperables se fundamenta en la colaboración entre distintos dominios de trabajo, para cada uno de los cuales predominan además herramientas de representación de procesos diferentes.

En este contexto, el esfuerzo requerido en la concepción y ejecución de tareas es determinante para el éxito de un proyecto. Por ello, el aprovechamiento del conocimiento, la reducción de la curva de aprendizaje de nuevas herramientas y acortar el tiempo requerido para la definición de nuevos procesos computacionales son factores que se ven favorecidos por la reutilización y adaptación de activos ya existentes. Por ejemplo, una parte de las tareas definidas en el proceso de segmentación de clientes estudiado (véase Sección V), como conversiones, normalización e incluso un algoritmo de agrupamiento, podría ser reubicadas de forma natural en un proceso aplicado a la detección de errores en datos procedentes de sensores dispuestos en maquinaria industrial.

No obstante, se han identificado una serie de dificultades relacionadas con la falta de formalización y estandarización. Por un lado, es necesario invertir gran cantidad de tiempo en la identificación y extracción de todas las características y elementos contemplados por cada WfMS, requiriendo para ello un número y variedad suficientes de flujos de trabajo. Nótese que la propuesta presentada requiere llevar a cabo dos conjuntos de conversiones por herramienta (WfMS al lenguaje intermedio, y viceversa), y no par a par entre herramientas. Sin embargo, la definición precisa y formal de los elementos de cada WfMS se hace imprescindible para garantizar la interoperabilidad semántica entre los activos. Por otro lado, debido a que cada herramienta proporciona sus propias características, o características comunes pero implementadas de forma muy distinta, no siempre existe una correspondencia directa entre elementos. En ocasiones, esto se resuelve definiendo equivalencias más complejas entre múltiples elementos de los flujos de origen y destino. Otras veces se trata de un problema de interoperabilidad técnica: por ejemplo, KNIME incrusta en su definición de flujos los archivos Java compilados, mientras que otras herramientas serializan la referencia a una dependencia externa. Para este tipo de interoperabilidades existen soluciones de código más frecuentes (p.ej. encapsulación, uso de servicios, etc.) frente a problemas relacionados con la semántica de las definiciones.

## VII. CONCLUSIONES

La dificultad en la definición de procesos computacionales y distintas fuentes de datos en la Industria 4.0 hace necesario el uso de mecanismos que favorezcan su representación y reutilización. Este trabajo presenta una propuesta de interoperabilidad entre flujos intensivos en datos de distintos WfMS mediante la correspondencia entre sus elementos.

Para ello, primero se han estudiado las características fundamentales de cada sistema por separado, definiendo de manera precisa el lenguaje de cada uno mediante un proceso de análisis y reingeniería. Después, tomando como base un lenguaje específico, independiente y bien definido para la ciencia de datos, se establecen correspondencias entre los elementos del lenguaje del WfMS y el lenguaje independiente, atendiendo a criterios de interoperabilidad semántica. De este modo, para cada nueva herramienta únicamente se requieren un número constante de equivalencias. Así pues, se ha comprobado para dos WfMS actuales, Taverna y Kepler, la posibilidad de migrar activos de un sistema a otro con el objetivo de reutilizarlos en situaciones diferentes. El proceso se ha automatizado mediante un prototipo web que ofrece su funcionalidad con API REST. En el futuro se completará la transformación entre los principales WfMS y se abordarán los retos discutidos.

## REFERENCIAS

- [1] L. Cao, "Data science: A comprehensive overview", *ACM Computing Surveys*, vol. 50, 2017.
- [2] J. Dean, and S. Ghemawat, "MapReduce: Simplified Data Processing on Large Clusters", *Communications of the ACM*, vol. 51, pp. 107–113, 2008.
- [3] I. Polato, R. Ré, A. Goldman, and F. Kon, "A comprehensive view of Hadoop research – A systematic literature review", *Journal of Network and Computer Applications*, vol. 46, pp. 1–25, 2014.
- [4] Workflow Management Coalition, "Terminology & glossary", Technical Report WPMC-TC-1011, 1999.
- [5] J. Yu, and R. Buyya, "A taxonomy of workflow management systems for grid computing", *Journal of Grid Computing*, vol. 3, no. 3, pp. 171 – 200, 2006.
- [6] P. Korambath, J. Wang, A. Kumar, L. Hochstein, B. Schott, R. Graybill, M. Baldea, and J. Davis, "Deploying Kepler Workflows as Services on a Cloud Infrastructure for Smart Manufacturing", *Procedia Computer Science*, vol. 29, pp. 2254 – 2259, 2014.
- [7] S.B. Japali, B. Archana, "Product recommendation for the day using fuzzy c-means and association rule generator in KNIME", *Proceedings of the 2017 International Conference On Smart Technology for Smart Nation*, pp. 556 – 559, 2018.
- [8] I. García-Magariño, G. Gray, R. Lacuesta, J. Lloret, "Survivability strategies for emerging wireless networks with data mining techniques: a case study with NetLogo and RapidMiner", *IEEE Access*, 2018.
- [9] R. Salado-Cid, and J.R. Romero, "Enabling the definition and reuse of multi-domain workflow-based data analysis", *Proceedings of the 16th International Conference on Intelligent Systems Design and Applications*, pp. 687 – 696, 2016.
- [10] P. Amstutz, M.R. Crusoe, N. Tijanić, "Common Workflow Language, v1.0 Specification", *Common Workflow Language working group*, 2016.
- [11] D.C. Schmidt, "Guest Editor's Introduction: Model-Driven Engineering", *IEEE Computer Society*, pp. 25 – 31, 2006.
- [12] R. Salado-Cid, J.R. Romero, "Lenguaje específico para el modelado de flujos de trabajo aplicados a ciencia de datos", *Actas de XXI Jornadas en Ingeniería del Software y Bases de Datos*, pp. 227 – 240, 2016.
- [13] M.R. Berthold, N. Cebren, F. Dill, T.R. Gabriel, T. Kotter, T. Meinl, P. Ohl, C. Sieb, K. Thiel, and B. Wiswedel, "KNIME: The Konstanz Information Miner", *Studies in Classification, Data Analysis, and Knowledge Organization*, Springer, 2007.
- [14] M. Hofmann, and R. Klinkenberg, "RapidMiner: Data mining use cases and business analytics applications", *Chapman & Hall/CRC*, 2013.
- [15] K. Wolstencroft, R. Haines, D. Fellows, A. Williams, D. Withers, S. Owen, S. Soiland-Reyes, I. Dunlop, A. Nenadic, P. Fisher, J. Bhagat, K. Belhajjame and F. Bacall, "The Taverna workflow suite: Designing and executing workflows of web services on the desktop, web or in the cloud", *Nucleic Acids Research*, vol. 41, no. W1, pp. 557 – 561, 2013.
- [16] I. Altintas, B. Ludäscher, S. Klasky, M.A. Vouk, "Introduction to scientific workflow management and the Kepler system", *Proceedings of the 2006 ACM/IEEE Conference on Supercomputing*, 2006.



# Estimando el tamaño de polímeros con redes neuronales

Ekhine Irurozki

Basque Center For Applied Mathematics (BCAM)

Bilbao (Spain)

Email: eirurozki@bcamath.org

Jose A. Lozano

Intelligent Systems Group (ISG)

UPV/EHU, Donostia/San Sebastián (Spain)

Basque Center For Applied Mathematics (BCAM)

Bilbao (Spain)

Email: ja.lozano@ehu.eus

**Abstract**—En este artículo presentamos dos problemas de predicción asociados a procesos de fabricación avanzada en el contexto de la industria 4.0. Los dos problemas están fuertemente relacionados aunque pueden ser tratados de manera independiente.

El presente problema se centra en la fabricación de una pieza sólida de polímero a partir de una mezcla de materias primas en estado líquido. La anchura de la pieza resultante viene definida por el molde en el que las materias primas son vertidas. En cambio, la altura depende de la cantidad de materiales que son vertidos y la proporción de los mismos además de factores externos como la temperatura, etc. Desafortunadamente el proceso químico implicado es de tal complejidad que no puede modelarse de forma exacta y es difícil contestar a las cuestiones de interés, como (i) ¿cuál será la altura de la pieza dados estos parámetros de fabricación? y (ii) ¿cuáles son los parámetros de fabricación más adecuados para fabricar una pieza de una altura dada? Para ayudar en el proceso de fabricación y resolver estas cuestiones se ha llevado a cabo un estudio desde el ámbito de la ciencia de datos.

**Index Terms**—redes neuronales recurrentes, regresión, series temporales, fabricación avanzada, optimización

## I. INTRODUCTION

Nuestro problema se centra en una empresa del sector de la fabricación de polímeros sólidos. Las materias primas son una serie de líquidos y las piezas finales tienen forma de barra de sección rectangular. La generación de estos sólidos está regida por las leyes de la química pero las ecuaciones que describen el proceso no están definidas de manera exacta. Ligeros cambios en la combinación de las materias primas provocan grandes cambios en la forma final de la pieza. Además de estos parámetros, otros parámetros externos, como los factores ambientales de temperatura y humedad afectan al proceso de fabricación.

La empresa que nos ocupa, como muchas industrias modernas, está fuertemente sensorizada, por lo que recoge gran cantidad de datos del proceso de fabricación. Por ello y dados los problemas enumerados antes, se ha decidido afrontar el problema de la estimación de altura desde el enfoque de la ciencia de datos.

This work has been supported by the Spanish Ministry MINECO through BCAM Severo Ochoa excellence accreditation SEV-2013-0323 and the project TIN2017-82626-R funded by (AEI/FEDER, UE) and the ELKARTEK programs, and by the MINECO through BCAM Severo Ochoa excellence accreditation SVP-2014-068574.

Como en todo proceso industrial, la optimización de los recursos es crucial. En este caso concreto, es importante que la altura de las piezas fabricadas sea lo más cercana posible a la altura de las piezas encargadas por los clientes ya que el material en el excedente de altura tiene que ser descartado con el consiguiente coste asociado.

El proceso de fabricación tiene, a grandes rasgos, estas características. Existen diferentes tipos de formulaciones, cada una con una proporción de materias primas diferentes y que resultan en materiales de propiedades diferentes. Cambios en las proporciones de los componentes afectan a las diferentes propiedades, incluyendo la altura de la pieza. Como decíamos en párrafos anteriores, las condiciones ambientales juegan también un papel importante en las propiedades de las piezas resultantes.

Un experto decide las cantidades de los componentes y la máquina vierte la mezcla de componentes en una cinta transportadora en movimiento, de manera que la forma final de la pieza es de barra de sección rectangular. La anchura de la pieza viene determinada por unas paredes asociadas a la cinta transportadora, pero no así la altura.

Durante el proceso de fabricación de una pieza el operario puede modificar los parámetros de la máquina para que la pieza se ajuste a la altura deseada. Sin embargo, no es posible conocer con exactitud la altura de la pieza hasta que el proceso de fabricación ha terminado. Esto implica que el experto ha de estimar la altura de la pieza y hacer las correcciones en las cantidades de materias primas basándose en esa estimación.

La máquina de mezclado dispone de sensores que miden la cantidad de cada producto vertido, temperatura de un producto o la velocidad a la que se mezclan. Se realizan lecturas de estos sensores con una frecuencia determinada.

Al acabar de fabricar la pieza se pasa por unos sensores dimensionales que miden la altura cada  $M$  milímetros. Estos puntos donde se mide la altura se denominan *cortes*, concepto que se repite a lo largo del presente artículo.

Los cambios en las materias primas o en las condiciones ambientales afectan a la altura de la pieza de forma desigual y de manera difícil de determinar. Sin embargo, el enfoque de la ciencia de datos, que tan buenos resultados ha obtenido en diversos procesos industriales, ofrece una herramienta novedosa para afrontar estos retos.

Aunque la descripción de la base de datos con detalle se realiza más adelante es importante remarcar la representación de la misma como una colección de series temporales, cada una de ellas correspondiente a una pieza concreta. En otras palabras, cada pieza se describe por una serie temporal multivariada que se representa con una matriz bidimensional donde cada columna se corresponde con un parámetro de fabricación y cada fila con la lectura en un tiempo determinado. Los parámetros de fabricación son datos recogidos de sensores (como, por ejemplo, la cantidad de una materia prima concreta vertida en cada momento o la temperatura de la misma).

## II. FABRICACIÓN

En esta sección se detallan los problemas que se tratan de resolver y se describe la base de datos.

### A. Objetivos

Para mejorar la eficiencia de la fabricación de piezas hay dos puntos cruciales para reducir el gasto de material. Ambos son los objetivos a tratar en este artículo y se formalizan de la siguiente manera:

**O1:** Predecir la altura en cada uno de los cortes de la pieza dados los parámetros de fabricación.

**O2:** Predecir los parámetros de fabricación dada una altura de la pieza y unas condiciones ambientales de humedad y temperatura.

Los dos objetivos están relacionados estrechamente aunque cada uno por sí solo resulta interesante.

### B. Data set, recogida y limpieza

Para crear la base de datos de las piezas es necesario juntar las variables de fabricación y de altura.

La base de datos está formada por los datos de 2504 piezas. Cada una de las piezas está descrita mediante una serie temporal multivariada con los valores recogidos por cada uno de los sensores de la máquina durante el tiempo en que dura el proceso de fabricación. La longitud de la pieza es variable y el número de cortes de las piezas de la base de datos está por lo general entre 100 y 200.

A lo largo de este artículo usaremos las denominaciones de serie temporal y secuencia de manera intercambiable.

El primer proceso a realizar en un contexto de ciencia de datos es el preproceso de la base de datos. En este caso el preproceso conlleva tanto tareas standard como otras diseñadas ad hoc para este problema concreto.

Los expertos aseguran que, con una probabilidad baja, los sensores de altura generan lecturas erróneas. Por ello, el preproceso comienza con la detección de errores en las lecturas de los sensores de altura según la definen los propios expertos. Una lectura en un corte  $p$ ,  $H_p$ , se considera errónea si  $|H_p - H_m| > 0.05H_{max}$ , donde  $H_m$  es la mediana de la altura en los 10 cortes anteriores y los 10 posteriores a  $p$  y  $H_{max}$ .

Una vez eliminadas las lecturas erróneas de sensores se eliminan aquellas variables que se mantienen constantes en todas las observaciones y para aquellas parejas de variables

que estén fuertemente correladas (más de 0.9) se elimina una de las dos variables.

Existen casos en los que una misma materia prima se distribuye en dos depósitos diferentes. Esta, puede salir con diferentes temperaturas por cada uno de los depósitos, o salir por uno de ellos y no por el otro. En este caso podemos unificar los datos de los diferentes tanques de la siguiente manera:

- La cantidad de producto total es la suma de las cantidades vertidas en los distintos depósitos.
- La temperatura total  $T$  viene dada por  $T = (m_1T_1 + m_2T_2)/(m_1 + m_2)$  siendo  $T_i$  la temperatura a la que se vierte desde el depósito  $i$  y  $m_i$  la cantidad que se vierte desde el depósito  $i$ .

Al final de este proceso hemos reducido considerablemente el número de variables a utilizar, desde las 215 iniciales a las 57 finales. Con el fin de proteger la confidencialidad, no se ofrecen detalles sobre las variables. En cualquier caso, se enumeran los distintos grupos de variables de que disponemos para poder entender mejor el resto del artículo.

- Variables **atmosféricas**, que incluyen humedad y temperatura.
- Variables de **fabricación** son todas aquellas que recogen los datos de los sensores de las materias primas, velocidad de la cinta transportadora, etc. Sobre estas variables el operario de la máquina puede actuar.
- Variables de **formulación**, variable categórica con 63 posibles valores diferentes, que define la composición base del material. Estos valores iniciales para los parámetros de fabricación son generalmente alterados durante la fabricación de la pieza.
- Variable de **altura** de la pieza.

## III. MODELADO MATEMÁTICO Y PREDICCIÓN

Como se describe en la Sección II-A, en este problema tenemos dos objetivos diferenciados. En los siguientes párrafos detallamos cada uno de los objetivos, los enfoques que utilizamos para resolverlos y las relaciones entre ambos.

### A. Objetivo O1

En el O1 se trata de predecir la secuencia de las alturas de la pieza en cada corte dada la serie con los parámetros de fabricación. Formalmente, hemos definido O1 como un problema de regresión de series temporales.

Una de las técnicas más habituales a la hora de tratar con series temporales es el de las *rolling windows* [2], que ya que permite el uso de técnicas clásicas de aprendizaje automático. Sin embargo, este enfoque no es válido para O1 por el hecho de que hasta que el proceso de fabricación de la pieza no ha sido completado no es posible medir la altura de la misma.

Otra alternativa muy popular en el ámbito del aprendizaje automático con series temporales es el de las redes neuronales, en particular en sus variantes de redes neuronales recurrentes (RNN por sus siglas en inglés).

Las RNN son una clase de redes neuronales capaces de hacer uso de información secuencial o temporal. Aunque las



RNN no se han usado habitualmente en la literatura de fabricación avanzada, son muy comunes en diversas áreas, muy especialmente en traducción automática [3], reconocimiento del habla [1] y reconocimiento de caracteres escritos a mano [8] entre otros.

Las redes neuronales básicas [5] logran mantener una *memoria* de los estados vistos con anterioridad mediante enlaces recurrentes en las neuronas internas. De esta manera, las salidas de un punto en la secuencia son tomadas como entrada en el siguiente punto de la secuencia y así se consigue capturar información de lo que ha sido calculado hasta ese momento.

Aunque en teoría la red puede almacenar información desde el principio de la secuencia, en la práctica solo es capaz de recordar unos pocos estados anteriores. Esto es debido a un fenómeno conocido como *vanishing/exploding gradients problem* por el que los pesos de la red no varían en el proceso de aprendizaje o tienden a infinito, ya que los gradientes que se calculan en los algoritmos de aprendizaje (backpropagation y métodos basados en gradientes) tienden a cero o tienden a infinito.

Las redes Long / short term memory (LSTM) se proponen [7] para intentar mitigar este problema y se han utilizado con éxito en diversos ámbitos [4]. Su diseño está inspirado en la circuitería más que en la biología ya que en cada una de las neuronas internas se definen puertas (una puerta de salida, otra de entrada y otra de borrar) y una célula de memoria. La función de las puertas es la de guardar la información de la célula de memoria permitiendo o bloqueando el flujo de información hacia ella.

En este trabajo consideramos ambos tipos de neuronas. Las arquitecturas consideradas se definen en la Sección IV.

### B. Objetivo O2

El segundo objetivo que se quiere cubrir en este artículo es el de estimar cuáles son los valores de los diferentes parámetros de fabricación para producir una pieza de un tipo (formulación) concreto, de una altura determinada y bajo unas condiciones atmosféricas concretas. Este objetivo lo enfocamos como un problema de optimización en el que tenemos dos componentes diferenciados, que son:

- el modelo de redes neuronales desarrollado en la sección anterior y
- una implementación del algoritmo *Covariance Matrix Adaptation Evolution Strategy* para la optimización numérica no lineal (CMA-ES por sus siglas en inglés).

Utilizando estos dos componentes, la estrategia que planteamos es utilizar el algoritmo de optimización CMA-ES para buscar en el espacio de parámetros de fabricación unos parámetros que, según el modelo de redes neuronales, produzcan una pieza con la altura deseada (o cuya altura se parezca lo más posible).

El algoritmo de optimización CMA-ES [6] es un método estocástico para la optimización numérica de funciones no lineares, multimodales, no convexas. Es un método evolutivo de caja negra y uno de los más utilizados en problemas de

alta dimensionalidad. El nombre viene del *covariance matrix adaptation* (CMA) un método para actualizar la matriz de covarianzas de la distribución.

Desde el punto de vista práctico, tres parámetros del algoritmo CMA-ES son necesarios para realizar una búsqueda con este algoritmo que son (i) la función objetivo a minimizar, (ii) una solución inicial y (iii) una varianza inicial en cada coordenada. Los valores específicos para estos parámetros se detallan en la Sección IV-B.

Tal y como hemos enunciado antes, los objetivos O1 y O2 están estrechamente relacionados dado el planteamiento que proponemos. Tanto que la solución para este segundo objetivo depende de los modelos propuestos para la solución del objetivo O1. De esta manera, la eficiencia en la resolución de este objetivo está condicionada por la calidad del algoritmo descrito en el objetivo O1.

## IV. EVALUACIÓN EXPERIMENTAL

En los siguientes apartados detallamos de qué manera se ha realizado la evaluación de las propuestas de este artículo y describimos los resultados que avalan esta propuesta.

### A. Resultados del objetivo O1

Para evaluar el modelo propuesto para la regresión en series temporales se han realizado una serie de experimentos con diversos parámetros

- *units* o número de neuronas, uno de [30, 50, 100, 150].
- *batch*, uno de [20, 50, 70, 90, 110].
- *model\_id*: cada uno de los modelos cuenta con una o dos capas con la siguiente arquitectura:
  - modelo 0: LSTM
  - modelo 1: LSTM con TimeDistributed layer
  - modelo 2: SimpleRNN
  - modelo 3: SimpleRNN con TimeDistributed layer
- *lenpart*: las piezas, que generalmente tienen entre 100 y 200 cortes, se particionan en subpiezas de *lenpart* cortes para que tengan todos la misma medida.
- *epochs*: 50
- *norm\_x*: valor 1 indica que los datos de las variables predictoras (las de fabricación y atmosféricas) se estandarizan y 0 que se normalizan.
- *norm\_y*: valor 1 indica que los datos de la secuencia a predecir (la de altura) se estandariza 0 que se normalizan.

La métrica utilizada en todos los casos es *mean squared error*, MSE. Se utiliza validación de 10 rodajas en cada una de las cuales se la base de datos se separa en los dos conjuntos, el grupo de entrenamiento y otro de test, de proporciones 0.7 y 0.3. Estos han de estar estratificados por tipo de formulación, de manera que las proporciones de cada tipo de formulación en las dos muestras sean constantes. Sin embargo, la variable de tipo de formulación no es relevante en ningún otro punto de la experimentación del objetivo O1, que sí utiliza las variables atmosféricas, de fabricación y altura.

En todos los experimentos realizados nos encontramos con que los primeros puntos son muy difíciles de aproximar. La red

necesita unos cuantos puntos para poder estimar con acierto la altura de la pieza. Por este motivo, a la hora de calcular el error en una red no se tiene en cuenta el error de los 10 primeros cortes.

Se aprende una red con cada una de las combinaciones de estos parámetros y se mide su error de entrenamiento y testeo durante las 50 épocas que dura el aprendizaje. El resultado después de 50 épocas se puede ver en la Figura 1, donde cada una de las 16 gráficas agrupa los experimentos con un mismo valor para los parámetros  $lenpart$ ,  $normx$  y  $normy$ .

Cada una de las ejecuciones se coloca en el punto X e Y se corresponden con los errores de entrenamiento y testeo. El color de cada punto indica el número de neuronas en el modelo.

Los ejes X e Y tienen los mismos valores en cada una de las gráficas para distinguir el sobreajuste de manera más sencilla.

Se puede ver que el comportamiento es similar para cualquier  $lenpart$  dados los mismos  $normx$  y  $normy$ . Se puede ver también que cuando se normalizan todos los datos la tendencia al sobreajuste es menor.

Tras un estudio general, observamos que los parámetros para los que estos modelos parecen comportarse mejor son  $lenpar = 50$ ,  $normx = 1$  y  $normy = 1$ . En la Figura 2 podemos ver los resultados de las ejecuciones para este conjunto de parámetros donde los colores de cada punto viene determinado por uno de los parámetros de la ejecución, de izquierda a derecha,  $batch$ ,  $units$  y  $model\_id$ . Se puede observar como los mejores resultados vienen dados por tamaños de  $batch$  pequeños, mayor número de neuronas y para los modelos 0 y 1.

Para analizar en detalle el comportamiento de la red proponemos la visualización de la Figura 3. Los parámetros de este experimento concreto son ( $units: 50$ ,  $batch: 20$ ,  $epochs: 100$ ,  $1\ model\_id$ ,  $60\ lenpart$ ,  $1\ normx$ ,  $1\ normy$ ). En el eje de las X están dispuesto los cortes de la pieza y en el de la Y la diferencia entre la altura real de la pieza y la altura estimada. Se han elegido 30 piezas de manera aleatoria del conjunto de entrenamiento y el error de cada uno de ellos viene dibujado con una línea de color diferente.

Se puede ver como los errores son casi constantes, no son picudos, y que la mayoría de ellos se agrupan entre los valores  $-0.02$  y el  $0.02$ .

## B. Resultados del objetivo O2

En esta sección describimos la configuración de la experimentación para este objetivo. Recordemos que encontrar un valor para cada una de las variables de fabricación de manera que junto con las variables ambientales generen una pieza de una altura dada. Para ello contamos con una red neuronal y con un algoritmo de optimización.

La red neuronal es la misma que hemos descrito en la sección anterior y que se visualiza en la Figura 3.

En el algoritmo de optimización hay que concretar una serie de valores, que son:

- La función objetivo a minimizar es la suma de la diferencia en cada corte entre la secuencia devuelta por la red y la altura real de la pieza.
- Una solución inicial, por cada variable de fabricación se toma la media de todos los cortes de todas las piezas del mismo tipo de formulación. Se consideran sólo aquellas piezas del conjunto de testeo.
- Una varianza inicial, por cada variable de fabricación se toma la varianza de todos los cortes de todas las piezas del mismo tipo de formulación. Se consideran sólo aquellas piezas del conjunto de testeo.

Para evaluar nuestra propuesta para este objetivo utilizamos el mismo conjunto de test que se utiliza para testar la red neuronal. Para una pieza dada tomamos sus variables de altura  $H$  y ambientales  $A$  de una pieza concreta. El reto es encontrar un conjunto de valores para cada una de las variables de fabricación  $F$  tales que, repetidas a lo largo del tiempo de fabricación, generen una pieza de una altura lo más parecida posible a la altura real de la pieza  $H$ . Para saber de qué altura sería la pieza fabricada con  $(F \cup A)$  utilizamos la red neuronal descrita anteriormente.

La Figura 4 muestra los resultados de nuestra propuesta. En la gráfica se muestra un grupo de barras por cada una de las variables de fabricación. Por motivos de confidencialidad los nombres de las variables (eje X) han sido eliminados. Dentro de cada grupo de tres barras, de derecha a izquierda, cada barra representa (i) el valor medio de esa variable en todos los cortes de la pieza, (ii) el valor óptimo que el algoritmo ha encontrado y (iii) el valor de la solución inicial para esa variable.

Como se puede ver, las soluciones iniciales pueden parecerse más a la media de la variable utilizada. Sin embargo, según el modelos de redes neuronales el error en la altura de la pieza generada es muy pequeño. No ha sido posible todavía probar los valores optimizados en el mundo real.

La Figura ?? muestra en detalle ese mismo experimento. En ella se muestra la altura real de la pieza, la altura predicha por el modelo de redes neuronales para los parámetros de fabricación y la altura predicha por el modelo de redes neuronales para los parámetros óptimos encontrados.

Esta búsqueda ayuda a unificar los criterios de los diferentes expertos y arroja luz sobre la manera en la que las diferentes alteraciones de componentes o combinaciones de componentes afectan a la altura de la pieza generada.

## V. CONCLUSIONES

En este artículo presentamos dos novedades en el ámbito de la industria 4.0.

La primera es un modelo para predecir la altura de una pieza fabricada basándose en sus variables de fabricación (materias primas) y en las condiciones ambientales. Este modelo está construido con redes neuronales, en particular con redes neuronales recurrentes debido a su capacidad de trabajar con series temporales.

La segunda es un algoritmo de optimización que busca los parámetros de fabricación óptimos para fabricar piezas



Fig. 1. Resultados de la experimentación intensiva con las distintas redes neuronales.

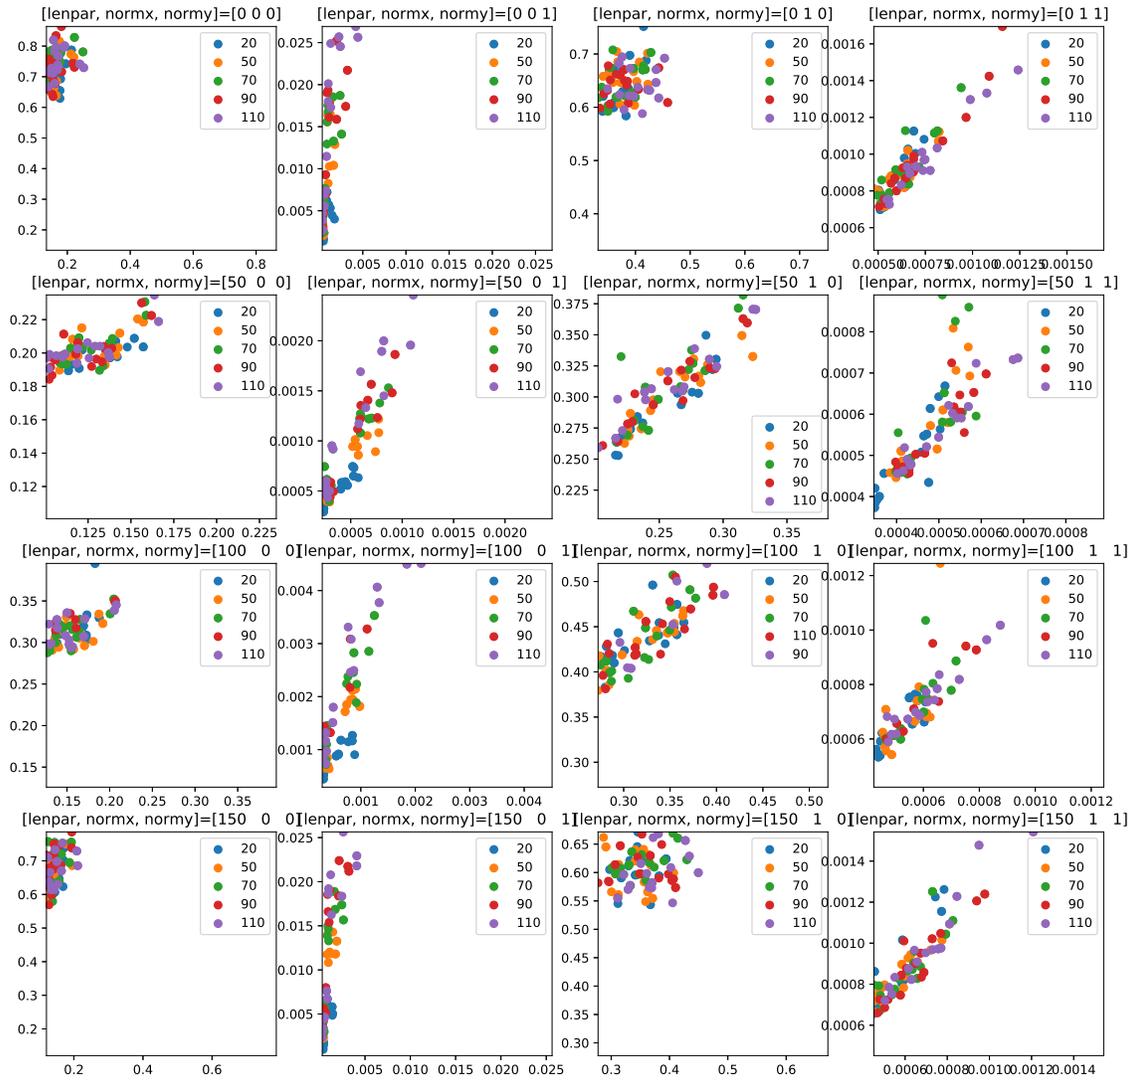


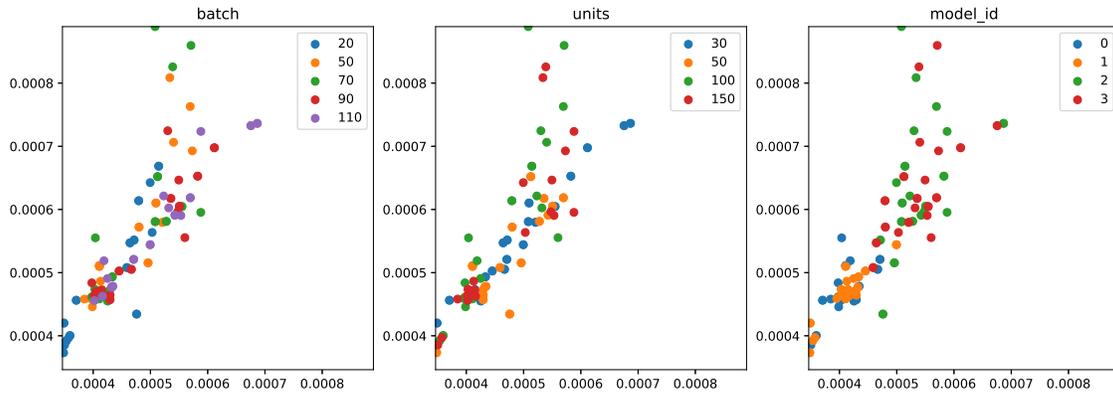
Fig. 2. Detalle de los experimentos con  $lenpar = 50$ ,  $normx = 1$  y  $normy = 1$ .

Fig. 3. Diferencia entre la altura real de la pieza y la predicha por nuestro algoritmo.

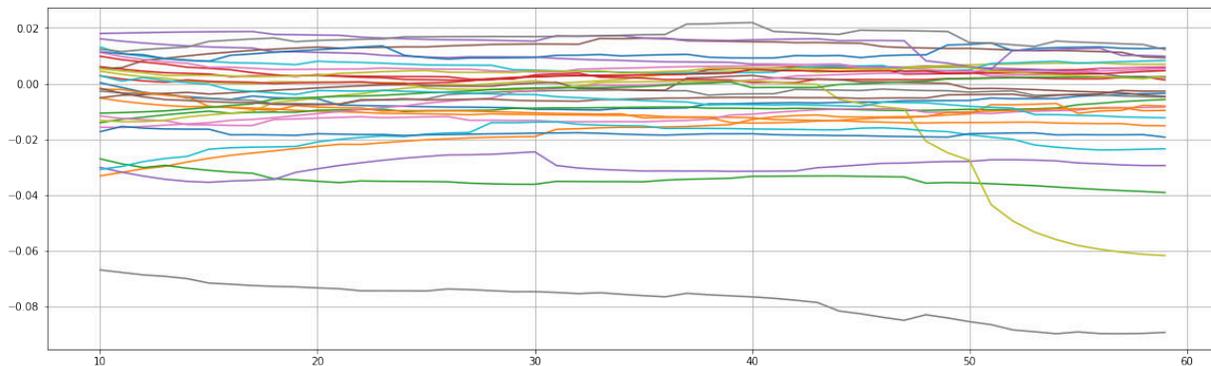
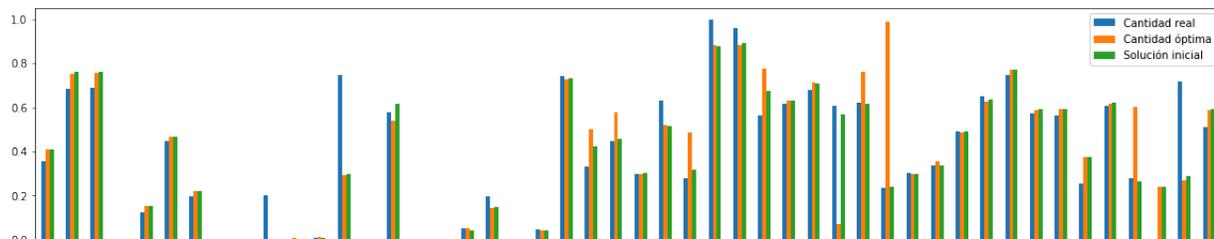


Fig. 4. Cantidad de materias primas reales y estimadas, tanto como solución inicial como optimizadas.



de una altura determinada bajo unas condiciones ambientales concretas. Esta búsqueda se efectúa utilizando el modelo de redes neuronales descrito anteriormente en este mismo artículo.

Las pruebas experimentales demuestran la eficacia de este enfoque y abre la puerta a futuros trabajos del uso de RNN en la industria para regresión en la industria de la fabricación avanzada.

#### REFERENCES

- [1] A.V. Allin Geo and K.P. Kaliyamurthie. Discourse recognition with deep learning. *International Journal of Pure and Applied Mathematics*, 116(10 Special Issue), 2017.
- [2] Peter Brockwell and Richard Davis. *Introduction to Time Series and Forecasting*. 2002.
- [3] Aaron Goodfellow, Ian, Bengio, Yoshua, Courville. Deep Learning (Chinese Translation). *MIT Press*, 2016.
- [4] Xiangang Li and Xihong Wu. Constructing Long Short-Term Memory based Deep Recurrent Neural Networks for Large Vocabulary Speech Recognition. *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 4520–4524, 2014.
- [5] L R Medsker and L C Jain. RECURRENT NEURAL Design and Applications. *New York*, 2001.
- [6] Nikohansen. pycma. [\url{https://github.com/CMA-ES/pycma}](https://github.com/CMA-ES/pycma), 2017.
- [7] Long Short and Term Memory. Long Short Term Memory. *Memory*, (1993):1–28, 1996.
- [8] Sheng Zheng, Xiangyun Zeng, Ganghua Lin, Cui Zhao, Yongli Feng, Jinping Tao, Daoyuan Zhu, and Li Xiong. Sunspot drawings handwritten character recognition method based on deep learning. *New Astronomy*, 45:54–59, 2016.



# Evolución del apoyo logístico en la Armada mediante tecnologías 4.0

F. Lamas López

Alférez de Navío (Dr. Ing.), Armada española,  
Arsenal de Cartagena  
Centro de Supervisión y Análisis de Datos de la Armada  
Cartagena, España

**Resumen**—La Armada Española se encuentra inmersa en la digitalización de sus procesos logísticos desde el diseño, construcción y ciclo de vida hasta el mantenimiento de sus unidades. Esto permitirá la automatización y predicción de las tareas de mantenimiento basado en la condición. El desarrollo de herramientas ligadas al mantenimiento predictivo estará centrado no solamente en los datos obtenidos en el CESADAR sino también por otros sistemas como los ligados al control de configuración de equipos embarcados. Este estudio exploratorio muestra como la información de ambos dominios, comportamiento mecánico y control de la configuración, deben ayudar a mejorar las predicciones de malfuncionamiento de un equipo. Para ello, se utilizan datos provenientes de dos motores propulsores de un buque generados desde el 2015 hasta el 2018. A partir de datos de comportamiento mecánico y análisis de los mismos pueden delimitarse modos de funcionamiento diferentes. Con estos registros y con ayuda de técnicas asociadas al aprendizaje automático, se pretende clasificar los diferentes modos de funcionamiento que afecten al normal mantenimiento de un propulsor antes de que ocurran. La predicción de distintos modos de funcionamiento de motores propulsores realizada en CESADAR-Central, puede ser de interés para las dotaciones de los buques en el caso de poder realizar las predicciones a bordo. Esto podría ayudar a prevenir modos de funcionamiento no deseados sobre los propulsores del buque durante sus operaciones. Se puede concluir que el uso de técnicas ligadas al aprendizaje automático es un método eficaz para la clasificación de patrones de un modo de comportamiento concreto. El uso de estas herramientas a bordo puede ayudar a prevenir modos de uso no deseados en tiempo real y debe ser una ayuda efectiva a la decisión de las dotaciones en operación.

**Palabras Clave**—*mantenimiento predictivo, aprendizaje automático, ayuda a la decisión, redes neuronales, clasificación de patrones*

## I. INTRODUCCIÓN

La Armada española se encuentra inmersa en la digitalización de sus procesos logísticos. Eso incluye todo el ciclo de vida de las unidades, desde su diseño hasta su uso pasando por la producción de las mismas. Esto se encuadra en el concepto de Apoyo Logístico 4.0 (AL 4.0). Los sistemas deben de ser capaces de prever su malfuncionamiento y comenzar automáticamente a gestionar su recambio o mantenimiento. Con el principal objetivo de aumentar la seguridad a bordo y la calidad de las operaciones. La actual predicción de eventos se alimenta de datos aportados por el Sistema Integrado de Control de Plataforma (SICP). Estos son datos relativos a sensores instalados en los sistemas de plataforma del buque, registrados diariamente en los servidores del Centro de Supervisión y Análisis de Datos de la Armada (CESADAR) situado en Cartagena. El SICP es el

encargado a bordo de los buques de la supervisión y el control de los sistemas de maquinaria y componentes del buque. Los datos registrados por los sensores enlazados al SICP son transmitidos diariamente al CESADAR, recibiendo este diariamente datos de sistemas monitorizados de 29 buques de la Armada.

Desde los años 90 ha habido un incremento de las técnicas de Minería de Datos como medio para obtener nuevo conocimiento. Los retos asociados a la gestión de grandes volúmenes de datos empiezan a dividirse en subprocesos para hacer abordable la tarea de obtener conocimiento de ellos. Diferentes métodos de clasificación y de regresión pueden utilizarse principalmente para predecir estados futuros o para clasificar estados similares de comportamiento. Estos métodos son aplicados en la literatura sobre sistemas monitorizados para inferir modos de funcionamientos en los equipos y optimizar el mantenimiento. Estas técnicas conciernen la búsqueda de modos de fallo o identificación de nuevos parámetros a partir de datos registrados. Sin embargo, pese a la literatura existente sobre análisis de fallos en motores navales, aún no ha sido aún presentado un estudio básico sobre los parámetros mecánicos necesarios para predecir mediante técnicas asociadas a la IA (como las redes neuronales) la descompensación de funcionamiento entre los cilindros de un motor embarcado. Con este objetivo, se propone diseñar una solución con la que a partir de los datos registrados por el SICP, se pueda notificar a la dotación del comportamiento esperado de un motor en los próximos instantes. En este estudio se va a reducir el problema, haciendo hincapié en la escalabilidad de este método a otros aspectos del comportamiento del propulsor. Por lo tanto es necesario definir parámetros mecánicos como inputs y por otro lado evaluar la eficacia según el número de parámetros utilizados.

## II. DEFINICIÓN DEL PROBLEMA

En los últimos meses se ha observado que tras un período de operación de un motor propulsor, si las temperaturas de sus cilindros estaban descompensadas respecto a la media de todos ellos, esto ha llevado a cabo en varias ocasiones a defectos en la combustión, falta de potencia e incluso podría haber sido originado por fallos en el inyector de un cilindro (atomizadoras). Todo dependía de en qué medida estaban descompensadas sus temperaturas respecto de la media. Debido a esto, en CESADAR se supervisa diariamente por un analista cada uno de los propulsores que han estado en operación durante las 24 horas precedentes al análisis visual de los datos. Si realmente es un malfuncionamiento que pueda dar un fallo inmediato de un componente, este debe ser detectado a bordo.

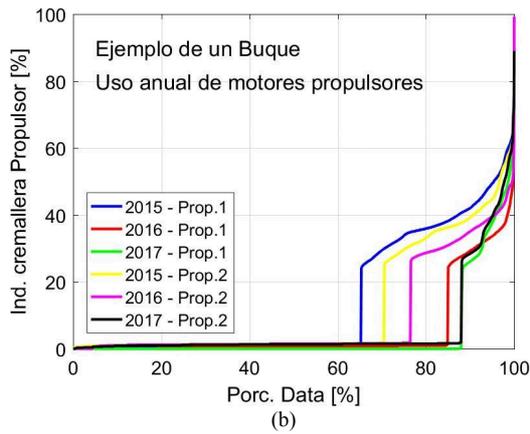
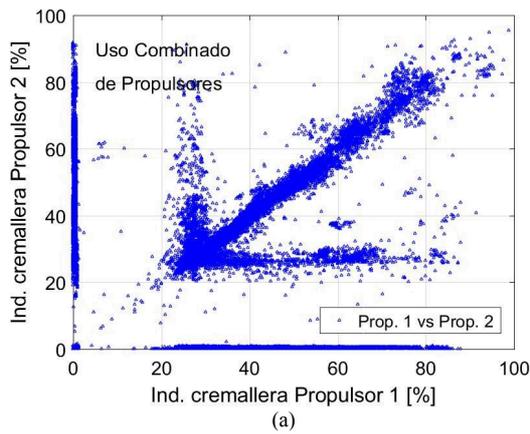


Fig. 1. (a) Uso combinado y (b) Uso anual en buque ejemplo de los propulsores 1 y 2 en el periodo 2015-2017

En este estudio se van a analizar datos de dos propulsores de un buque ejemplo entre el 2015 y el 2018. Los datos extraídos directamente del SICP, sin conversión alguna por el analista son: el Índice de Cremallera ( $IC$ ), las revoluciones por minuto del propulsor ( $RPM$ ), la temperatura media de las dos líneas de cilindros ( $\bar{T}$ ), y la temperatura de gases de escape por cilindro  $T_i$ . Estos datos son registrados con una frecuencia de muestreo  $f_s=6s$ . En el conjunto de los cuatro años mencionados se han obtenido en torno a 8M de registros. En la Fig. 1a se expone el uso combinado de los dos propulsores. Se pueden distinguir principalmente tres modos de uso combinado cuando no están apagados ambos (0,0). El primer modo combinado conlleva utilizar solamente uno de los dos, pero siempre a partir del 30% del  $IC$ . Este índice representa la relación de potencia demandada al propulsor en porcentaje (%). En el segundo modo se aprecia que se utiliza uno de los propulsores con una relación de potencia (o  $IC$ ) fija del 30% mientras que el otro puede funcionar con un  $IC$  del 30% al 100%. El último modo es el relativo a un uso de los dos propulsores a la misma relación de potencia, siempre mayor del 30%. Respecto al total de datos registrados, en la Fig. 1b se aprecia que hasta un 40% de los mismos representan tiempo de operación de los propulsores. Se puede describir que la mayor parte de operaciones de los propulsores se realizan con  $IC$  de entre 30% y 60%. En ellos se pueden apreciar un similar uso para un mismo año, y sus diferencias anuales de uso en este barco ejemplo en cuestión. Se aprecia igualmente en la Fig. 1b que la mayor parte del tiempo de operación ( $TO>80\%$ ) se realiza entre el 30% y el 42% de  $IC$ . Sin embargo, la respuesta del propulsor ante un comando de  $IC$  concreto no se desarrolla siempre de la misma manera y depende múltiples factores externos como el escaramujo, lastres, etc (Fig. 2).

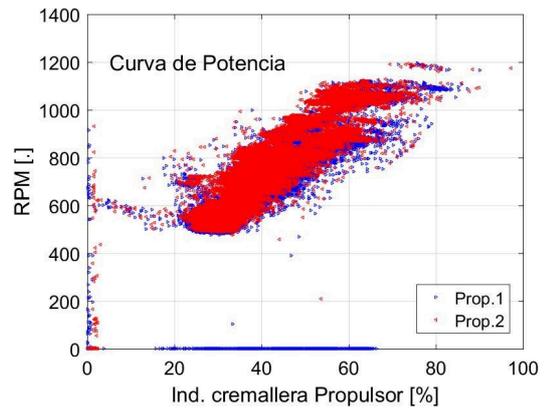


Fig. 2. IC vs RPM en buque ejemplo

Las RPM del motor van de 500 a 1200  $RPM$  en el rango de tiempo representado en la Fig. 2. De entre las variables registradas por SICP de cada propulsor, hay una a la que se le presta especial atención diariamente, como indicador del correcto funcionamiento del mismo, esta es la temperatura de gases de escape de cada uno de los cilindros ( $T_i$ ). El propulsor del buque ejemplo está compuesto por dos líneas (A y B) de 8 cilindros cada una. A partir de lo expuesto en la Fig. 3 se aprecia que el comportamiento de los cilindros adyacentes en cada una de las líneas evoluciona de forma análoga en el rango de temperaturas medias  $\bar{T} > 250^\circ C$ ,  $\bar{T}_{A,B}=(250, 250)$ . Se deben tener en cuenta ambas líneas en los cálculos.

A mayor abundamiento, las temperaturas medias de gases de escape ( $\bar{T}$ ) evolucionan de una forma cuasi-lineal y más homogénea a partir desde  $IC=40\%$  (Fig. 4a). Se pueden distinguir dos regímenes de evolución de temperaturas medias en ambos propulsores, de  $550^\circ C > \bar{T} > 300^\circ C$  para  $IC$  comprendidos entre 25 y 40 % y de  $600^\circ C > \bar{T} > 550^\circ C$  para  $IC$  comprendidos entre 40 y 100 %. Para realizar una clasificación de modos, se va a utilizar un tercer parámetro, calculado a partir de las variables registradas, que pueda integrar el efecto de las anteriores, como en otros casos de clasificación de eventos. El parámetro, denominado desviación de temperaturas acumulada, que representa las diferencias absolutas de cada cilindro respecto a la media, se calcula según (1) y (2):

$$\Delta T_i = \text{ABS} \left( T_i - \frac{\sum_{i=1}^{16} T_i}{n} \right) = \text{ABS} (T_i - \bar{T}) \quad (1)$$

$$\left( \sum \Delta T_i \right) = \left( \sum_{i=1}^{16} \Delta T_i \right) \quad (2)$$

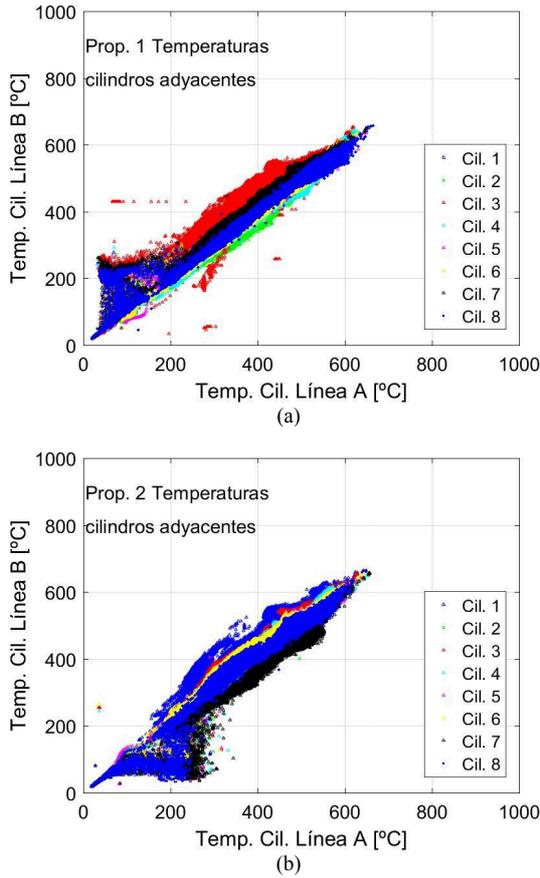


Fig. 3. Temp. de gases de escape en cilindros adyacentes (a) propulsor 1 y (b) propulsor 2

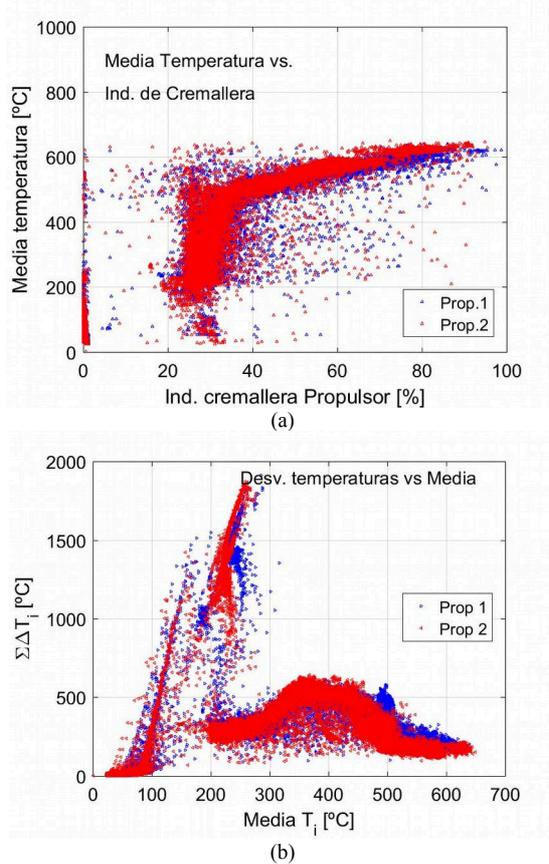


Fig. 4. (a) Media de temperaturas de gases de escape por cilindros vs. IC y (b) Desviación de temperaturas vs media de temperaturas en propulsores 1 y 2

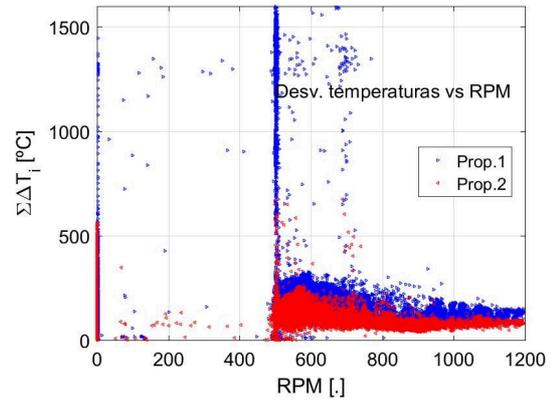


Fig. 5. Desviación de temperaturas vs RPM para los propulsores 1 y 2

Al representar la desviación de temperaturas acumulada respecto a la media (**Fig. 4b**), se observa un pico para temperaturas medias  $\bar{T} > 250^\circ\text{C}$  que no se repite a lo largo del resto de temperaturas medias registradas en ambos propulsores. En mayores  $IC$  se comporta de forma más estable el motor. Hay un incremento no tan notable como en el rango de  $250\text{-}300^\circ\text{C}$ , cuando los cilindros del motor se encuentran en torno a  $400^\circ\text{C}$  de media. Este último caso, aún en la región inestable del motor, con  $IC < 40\%$  (**Fig. 4a**). Gran parte de desviaciones de temperaturas se produce cuando el eje del propulsor está rotando a  $RPM=500$ , lo que suele estar aparejado a  $IC \approx 30\%$  (**Fig. 5**).

### III. RED NEURONAL DE CLASIFICACIÓN

La ciencia de datos es una rama de la inteligencia artificial (IA) en la cual se busca que un sistema sea capaz de aprender de datos que pueden ser usados para hacer predicciones y reconocer patrones de comportamiento. El aprendizaje de este sistema artificial puede ser supervisado según indicadores externos. Una red está formada por un conjunto de neuronas de entrada (donde se introducen los valores de los parámetros de entrada para cada medida), capas sucesivas de neuronas ocultas y una última capa de neuronas de salida. Cada conexión entre neuronas de capas adyacentes está ponderada por un peso y son activadas mediante un peso externo denominado umbral de activación. La función que aplica una neurona sobre los datos de entrada y los pesos se denomina función de transferencia y es no lineal, además toma su valor máximo cuando  $x=0$ . Los pesos que intervienen sobre cada conexión ( $\omega_{ij}$  desde la neurona  $i$  en la capa anterior hasta la neurona  $j$  de la siguiente capa) son automáticamente ajustados iterativamente. El método utilizado, es una función de entrenamiento que actualiza los valores de peso acorde al gradiente escalado conjugado (*scaled conjugate gradient method*). Para las redes de clasificación habrá tantas neuronas de salida como posibles patrones de comportamiento se consideren. Como ejemplo para mostrar cómo se calibran los pesos asociados a cada par de neuronas, se tendrá en cuenta una red de 4 capas (una de entrada, dos ocultas y una de salida) para ver las expresiones en su forma desarrollada. En este método los pesos, ligando cada dos neuronas en capas adyacentes, se ajustan siguiendo la ecuación (3).

$$\frac{\partial y_i}{\partial \omega_{jk}^{(1)}} = x_j a_k^{(2)} (1 - a_k^{(2)}) \cdot \left[ \sum_{p=1}^{n_3} \omega_{kp}^{(2)} a_p^{(2)} (1 - a_p^{(3)}) \omega_{pi}^{(3)} \right] \cdot y_i (1 - y_i) \quad (3)$$

El sumatorio de los productos indicados indica que hay que contemplar todos los caminos posibles desde la salida  $y_i$  hasta la neurona de entrada  $x_j$ . en este caso las entradas a la red se representan como  $x$ , y las salidas, o resultados, como  $y$ . Cada neurona tiene asociado además de un peso (que une dos neuronas de capas sucesivas), un umbral de activación. Si se realiza el diferencial respecto el umbral asociado a cada neurona de las capas ocultas ( $u_i$ ), el resultado se muestra en la ecuación (4).

$$\frac{\partial y_i}{\partial u_i^{(2)}} = a_k^{(3)} (1 - a_k^{(3)}) \omega_k^{(3)} y_i (1 - y_i) \quad (4)$$

En cambio, si en vez de ser sobre el umbral, la diferencian de la expresión de salida  $y_i$  sobre el peso que une dos neuronas situadas entre la tercera y cuarta capa sería la mostrada en la ecuación (5).

$$\frac{\partial y_i}{\partial \omega_{jk}^{(2)}} = a_j^{(2)} a_k^{(3)} (1 - a_k^{(3)}) \omega_k^{(3)} y_i (1 - y_i) \quad (5)$$

El objetivo de las redes neuronales es calcular los pesos que ligan dos neuronas y los umbrales de activación, para converger hacia los resultados que se busquen en el menor número de iteraciones (épocas, *epochs*). La calidad de los pesos logrados se justifica mediante el error medio cuadrático de los resultados respecto a la salida deseada (*Mean Square Error, MSE*). El *MSE* entre el resultado obtenido y el resultado deseado se calcula mediante la expresión (4) siguiendo la regla de la cadena.

$$\frac{\partial e}{\partial \varepsilon} = \sum_{i=1}^{n(4)} \frac{\partial e}{\partial y_i} \cdot \frac{\partial y_i}{\partial \varepsilon} \quad (6)$$

Siendo  $e$  el error entre las soluciones esperadas y obtenidas. Simplificando y aplicando la regla de la cadena:

$$\frac{\partial e}{\partial y_i} = -(s_i - y_i) \quad \text{ya que} \quad e = \sum_{i=1}^{n(4)} \frac{1}{2} (s_i - y_i)^2 \quad (7)$$

Las iteraciones se detienen cuando se consigue un error mínimo tras seis iteraciones seguidas sin mejorar. El conjunto de datos con el que se persigue entrenar una red neuronal se divide en tres: entrenamiento, validación y test.

#### IV. MODOS DE FUNCIONAMIENTO Y EXPERIMENTACIÓN

Primeramente se han descartado todos los registros que corresponden a  $IC < 10\%$  en los que el motor no está operando. Los registros restantes se han discretizado en 4 modos de funcionamiento, atendiendo a una distribución lo más regular (compensada) posible entre modos. Los registros utilizados en este punto corresponden a una frecuencia de muestreo  $f_s = 1 \text{min}$ , mayor respecto a la de registros brutos y reduciendo la redundancia de datos **Tabla 1**.

La distribución porcentual de valores de desviación de temperaturas respecto a la media se refleja en la **Fig. 6** los límites de los modos considerados en la **Tabla 1**. A partir de  $\sum \Delta T_i = 600 \text{ }^\circ\text{C}$  ( $\approx 2\%$  de los registros) hay un incremento notable de la tendencia de desviación de temperaturas, y presentan una mayor descompensación respecto a la media. El porcentaje de registros de este modo es estable para

todos los buques y años (en torno al 2%). Los otros 3 grupos de datos (MODO1, MODO2, y MODO3) presentan en torno al 33% de registros por cada uno, depende que propulsores (barco y año) tener en cuenta, pero la variabilidad es menor al  $\pm 10\%$  respecto del tercio total de registros con los límites definidos. Esta repartición de registros se muestran en la **Fig. 7**.

Modo	Rango de $\sum \Delta T_i$ ( $^\circ\text{C}$ )
Modo1	$\sum \Delta T_i < 200 \text{ }^\circ\text{C}$
Modo2	$200 \text{ }^\circ\text{C} < \sum \Delta T_i < 300 \text{ }^\circ\text{C}$
Modo3	$300 \text{ }^\circ\text{C} < \sum \Delta T_i < 600 \text{ }^\circ\text{C}$
Modo4	$600 \text{ }^\circ\text{C} < \sum \Delta T_i$

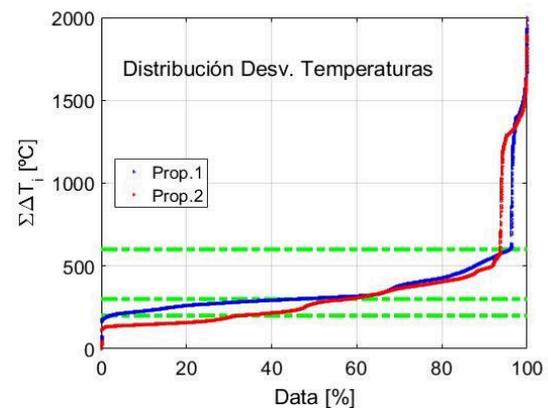


Fig. 6. Distribución de datos de desviación de temperaturas en buque ejemplo durante 1 año

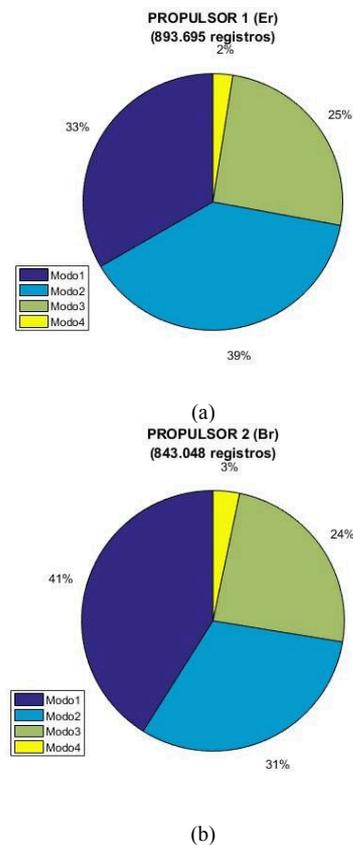


Fig. 7. Modos de funcionamiento registrados, durante funcionamiento, en tres buques equivalentes entre 2015-2018 en (a) propulsor 1-Estribor y (b) propulsor 2-Babor



El objetivo es crear una red capaz de clasificar los 4 modos de funcionamiento expuestos (Outputs), desde el más compensado (MODO1) hasta el más descompensado (MODO4), a partir de unos parámetros de entrada (Inputs). Se establecen 3 tipos de experimentos que se diferencian por el número de Inputs a tener en cuenta en cada uno de ellos, según lo descrito en la **Tabla 2**.

Conjuntos	Inputs (N)	Outputs	Número de registros
Primer experimento	$\bar{T}$ , IC, RPM, $\Delta T\bar{i}$ (Línea A) (11)	4 Modos	163.597 (1 año) Buque ejemplo
Segundo experimento	$\bar{T}$ , IC, RPM (3)		
Tercer experimento	$\bar{T}$ , IC, RPM • (t-30min, t-60min) (9)		

En el primer experimento se tienen en cuenta 11 parámetros (diferencias de temperaturas sólo de cilindros de la línea A), en el segundo 3 parámetros y en el tercer experimento son 9 parámetros correspondientes a los 3 del segundo experimento más dos conjuntos más de los mismos, correspondientes a registros temporales 30 y 60 minutos precedentes a los del momento  $t$  en el que se quiere hacer la predicción.

La red neuronal diseñada tiene una capa oculta de 24 neuronas y una capa oculta de 24 neuronas para cada modo de funcionamiento considerado. Se utilizan el 65% de registros en fase de entrenamiento, el 20% en fase de validación y el 15% restante en fase de test.

V. RESULTADOS Y DISCUSIÓN

En el primer experimento, la tasa de verdaderos positivos para los 4 modos de funcionamiento es de en torno a 93,5% (**Tabla 3**), teniendo la red mayor facilidad de clasificar a los registros pertenecientes al MODO4 (98% de verdaderos positivos) que se supone como el más contraproducente para el correcto funcionamiento y desgaste del motor propulsor. En el segundo experimento se reducen drásticamente el número de parámetros de Input (hasta 3), ellos correlacionados positivamente entre sí (tras análisis PCA). En este experimento se observa una reducción de la tasa de verdaderos positivos hasta el 76% (**Tabla 3**) en cada una de las fases de entrenamiento, validación y test. Al contrario que en el primer experimento, aquí se aprecia una mayor tasa de falsos positivos entre los Modos opuestos MODO 1y MODO4, lo que resulta en un riesgo para poder predecir correctamente posibles estados no deseados del propulsor. Esta tasa de falsos positivos aumenta hasta el 61%. En lo que respecta al tercer experimento, aun sirviéndose de los mismos Inputs que el primero, este utiliza valores de los Inputs de registros realizados 30 y 60 minutos antes del momento en el que se pretende predecir el modo de funcionamiento del motor. El número total de parámetros de entrada es intermedio a los dos experimentos previos pero los resultados se aproximan bastante a los del primer experimento, obteniendo una tasa global de verdaderos positivos mayor al 92% (**Tabla 3**). El punto negativo de utilizar esta configuración de parámetros de entrada es la alta tasa de falsos positivos que presentan entre los modos de funcionamiento 1 y 4, mientras que entre los modos 2 y 3 se alcanzan tasas de verdaderos positivos muy altas.

Conjuntos	Entrenamiento	Validación	Test
Primer experimento	93.3%	93.4%	93.6%
Segundo experimento	76.0%	76.2%	76.5%
Tercer experimento	92.4%	92.6%	92.5%

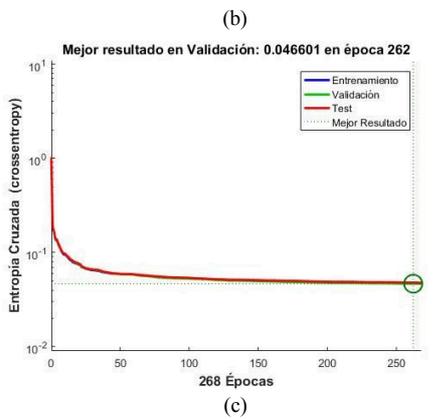
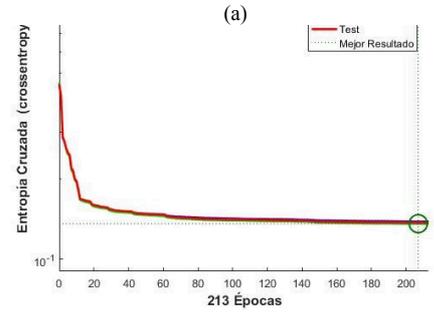
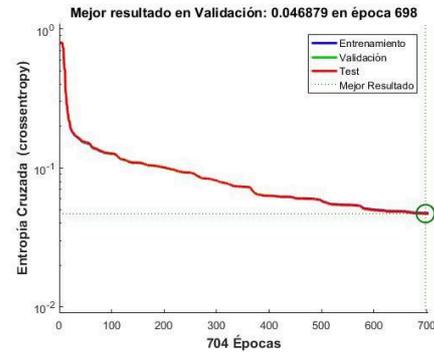


Fig. 8. Convergencia en validación para (a) primer, (b) segundo y (c) tercer experimento

Al analizar las curvas de aprendizaje obtenidas en los tres experimentos de forma conjunta, se puede apreciar las diferencias en la convergencia hacia la solución de error óptimo, siendo los errores finales obtenidos muy similares para los experimentos 1 y 3 (**Fig. 8**). Se converge más tarde cuando mayor número de parámetros Input se consideran (experimento 1). Esto se traduciría en el futuro en un mayor tiempo de computación para cada problema planteado.

VI. CONCLUSIONES Y PERSPECTIVAS

El análisis realizado muestra que los motores propulsores analizados son operados normalmente a una relación de potencia inferior a su capacidad máxima ( $IC=30\%-42\%$  durante un tiempo de operación  $TO>80\%$ ), lo que parece poder impactar sobre el comportamiento normal de sus componentes. Igualmente, se ha descrito un

modo de funcionamiento característico ( $\approx 2\%$  de los registros totales en operación) a partir de una desviación acumulada de temperaturas sobre la media de  $\sum \Delta T_i = 600^\circ\text{C}$ , en la que aumenta de forma más notable este parámetro, indicador de descompensación en el comportamiento de los cilindros del propulsor. Mayores valores del parámetro  $\sum \Delta T_i$  pueden desembocar en un funcionamiento no deseado del propulsor. En cuanto a los datos, los motores propulsores análogos, resultan en comportamientos y distribuciones análogas de sus modos de funcionamiento. Esto afianza la coherencia de los datos equivalentes para equipos análogos. Finalmente, se puede concluir que el uso de técnicas asociadas al aprendizaje automático para clasificación de eventos supone una herramienta útil de ayuda a la decisión para las dotaciones. Para un mejor conocimiento de los sistemas a mantener por la Armada española, es de capital importancia ligar datos mecánicos como los presentados en este estudio exploratorio a datos de configuración logística. Esto supondrá obtener capacidades para predecir patrones de comportamiento en elementos configurados o actores que participen en el apoyo logístico.

#### AGRADECIMIENTOS

Este estudio exploratorio se ha realizado en el marco del proyecto de *Apoyo Logístico 4.0* liderado por la Dirección de Sostenimiento (DISOS) de la Jefatura de Apoyo Logístico (JAL) de la Armada española. El autor quiere agradecer al CN D. Juan Díaz del Río Durán, CN D. Diego Carriazo Hernández y al resto de personal de CESADAR-Central, CF D. Fernando Escondrillas Gómez, SGT1 D. Francisco Preciado Conesa y OTA D. José Carlos García Pérez por su apoyo a la consecución de los resultados expresados en este estudio.

#### REFERENCIAS

- [1] J.D. González-Aller Lacalla and F. Lamas López, "Evolución del CESADAR 'Prediciendo el futuro, eficiencia en el sostenimiento, eficacia de la flota'" Rev. Gen. Mar. no. Agosto-Septiembre, p. 14, 2018.
- [2] F. Escondrillas and F. Lamas López, "Informe Estado General CESADAR 2018 (Informe Interno Confidencial ARMADA)," Cartagena, 2018.
- [3] U. Fayyad, G. P. Shapiro, and P. Smyth, "From Data Mining to Knowledge Discovery in Databases," AI Mag. Am. Assoc. Artif. Intell., no. Fall, p. 18, 1996.
- [4] R. Brachman and T. Anand, "The Process of Knowledge Discovery in Databases: A Human-Centered Approach," Adv. Knowl. Discov. Data Min., pp. 37–58, 1996.
- [5] C. Wang, "Embedded Sensing for Online Bearing Condition Monitoring and Diagnosis," University of Massachusetts, Amherst, MA, 2001.
- [6] P. W. Tse and D. P. Atherton, "Prediction of Machine Deterioration Using Vibration Based Fault Trends and Recurrent Neural Networks," J. Vib. Acoust., vol. 121, no. July, pp. 355–362, 1999.
- [7] H. Taplak, I. Uzmay, and S. Yildirin, "Design of artificial neural networks for rotor dynamics analysis of rotating machine systems," J. Sci. Ind. Res., vol. 64, no. June, pp. 411–419, 2005.
- [8] Y. Shao and K. Nezu, "Prognosis of remaining bearing life using neural networks," J. Syst. Control Eng., vol. 214, no. 3, pp. 217–230, 2000.
- [9] Y. Y. Liu, Y. F. Ju, C. D. Duan, and X. F. Zhao, "Structure damage diagnosis using neural network and feature fusion," Eng. Appl. Artif. Intell., vol. 24, pp. 87–92, 2011.
- [10] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, and D. J. Inman, "Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks," J. Sound Vib., p. 17, 2016.
- [11] M. S. Hossain, O. Z. Chao, Z. Ismail, S. Noroozi, and K. S. Yee, "Artificial Neural Networks for Vibration Based Inverse Parametric Identifications: A Review," Appl. Soft Comput., 2017.
- [12] F. Lamas-Lopez, "Field and laboratory investigation on the dynamic behavior of conventional railway track-bed materials in the context of traffic upgrade," Ecole Nationale des Ponts et Chaussées, 2016.
- [13] F. Lamas López, J. M. Riola Rodríguez, and J. D. González-Aller Lacalle, "La aplicación de Inteligencia Artificial (IA) en industria 4.0: mantenimiento predictivo de equipos embarcados," in 56o congreso del colegio de Ingenieros Navales y Oceánicos., 2017, p. 11.
- [14] C. Sharma, "Big data analytics using neural networks," San José State University, 2014.
- [15] M. Sánchez-Montañés, L. Lago, and A. González, "Métodos avanzados en aprendizaje artificial: Teoría y aplicaciones a problemas de predicción," Madrid, 2014.
- [16] Y. Saad, Iterative methods for sparse linear systems, vol. 3, no. 4. Philadelphia: Society for Industrial and Applied Mathematics, 2000.

---

# Doctoral Consortium

JOSÉ RIQUELME  
HUMBERTO BUSTINCE





---

# Doctoral Consortium

## SESIÓN 1







# Estrategias y herramientas de apoyo para facilitar la aplicabilidad de los algoritmos bio-inspirados y otras metaheurísticas

Mohammed Mahrach, Gara Miranda, Coromoto León

*Dpto. Ingeniería Informática y de Sistemas*

*Universidad de La Laguna*

*Avenida Astrofísico Francisco Sánchez, s/n.*

*Apto. 456, 38200, San Cristóbal de La Laguna,*

*Santa Cruz de Tenerife, España*

*mmahrach@ull.edu.es, gmiranda@ull.edu.es, cleon@ull.edu.es*

**Resumen**—Actualmente existen diversas plataformas y entornos software para la optimización, con algoritmos evolutivos y otras metaheurísticas bio-inspiradas. Sin embargo, lograr una clara separación entre el problema y las implementaciones de los resolutores sigue siendo un desafío, debido a muchas dificultades tanto de representación del espacio de soluciones, como de búsqueda dentro de dicho espacio. En la mayoría de las estrategias de exploración, tanto la representación de la solución como la forma en que se pasa de una solución a otra, depende en gran medida del propio algoritmo. De esta forma, el uso de un algoritmo o estrategia concreta, indirectamente implica que el usuario debe proporcionar una implementación diferente y adecuada para cada caso, así como diferentes tipos de operadores de variación (por ejemplo, los operadores de cruce y mutación en los algoritmos evolutivos). Esto puede resultar una tarea bastante compleja y requiere de mucho tiempo y experiencia, pues no sólo hay que conocer las características del problema a resolver sino también los detalles de la técnica algorítmica a aplicar. Esto dificulta especialmente la aplicación de estas técnicas por parte de usuarios no expertos en este ámbito de investigación. Es por ello, que el principal objetivo de este proyecto es aumentar la aplicabilidad de los algoritmos “bio-inspirados” y otras metaheurísticas, para la resolución de problemas de optimización “multi-objetivo” en los que existen múltiples objetivos a optimizar simultáneamente. Para ello se pretende diseñar y desarrollar una interfaz con algunas de las metaheurísticas más extendidas, de forma que puedan ser utilizadas en entornos empresariales o por parte de usuarios no expertos.

**Index Terms**—Metaheurísticas, Algoritmos bio-inspirados, Optimización combinatoria, Optimización multi-objetivo, Ingeniería del software.

## I. INTRODUCCIÓN

La resolución de problemas multi-objetivo mediante metaheurísticas es uno de los temas más investigados en el ámbito de las Ciencias de la Computación. Una de las principales dificultades a la hora de implementar metaheurísticas es cómo definir una representación general para las soluciones de los problemas, de modo que el espacio de búsqueda para el problema correspondiente pueda estar

completamente representado. Otra dificultad, una vez se ha definido el espacio de búsqueda que representa todas las posibles soluciones, es definir un mecanismo para explorar ese espacio. Este mecanismo de exploración debería definir los movimientos o criterios para seleccionar las próximas soluciones a tener en cuenta. Para superar estas dificultades, la misión de este trabajo es poder implementar optimizadores a un nivel de descripción abstracto no específico del problema, de modo que haya una separación entre el problema y su método de solución. De esta forma, se podría evitar la tarea de codificación de soluciones personalizadas a cada problema pues resulta bastante difícil y requiere de mucho tiempo y esfuerzo, especialmente para usuarios no expertos.

Este trabajo está organizado de la siguiente manera. Los antecedentes y estado actual del tema (tanto en lo que respecta a metaheurísticas y estrategias de optimización, como en relación a herramientas de Ingeniería del Software para el desarrollo de herramientas e interfaces de usuario) se identifican en la sección I. En la sección II se presentan los objetivos planteados y el interés de los mismos. Por su parte, en la sección III se incluye una breve descripción de la metodología a seguir y el plan de trabajo propuesto. Finalmente, en la sección IV se plantea la relevancia social y teórica de la investigación y los motivos por los cuales se lleva a cabo el estudio.

## II. ANTECEDENTES

La optimización combinatoria es una rama de la optimización en Matemáticas Aplicadas y en Ciencias de la Computación, relacionada con la Investigación Operativa, la Teoría de Algoritmos y la teoría de la Complejidad Computacional. El propósito de la Optimización Combinatoria es encontrar objetos matemáticos discretos que maximicen (o minimicen) una determinada función objetivo, de tal forma que las variables de dicha función representan las decisiones que se pueden tomar y que modifican el valor de esa función y estén sujetas a una serie de restricciones que algunas de las

variables deben satisfacer [1]. Generalmente, estos objetos se denominan estados y al conjunto de todos los posibles estados candidatos se le denomina espacio de búsqueda. La naturaleza de los estados y del espacio de búsqueda viene determinada por el tipo de problema y por la formulación que se haga del mismo.

Aquellos problemas que se centran en la optimización de una única función objetivo reciben el nombre de problemas mono-objetivo. Sin embargo, en multitud de problemas reales en ingeniería es necesario optimizar simultáneamente un conjunto de funciones objetivo. A este tipo de problemas se les denomina problemas multi-objetivo. En la optimización de problemas multi-objetivo, se podrían ponderar los distintos objetivos para obtener una única función y, por tanto, poder aplicar los métodos clásicos de resolución. Sin embargo, existe un conjunto de algoritmos especialmente diseñados para afrontar la resolución de los problemas multi-objetivo como tales. Estos algoritmos tienen en cuenta que es posible que no exista una única solución optimizando todos y cada uno de los objetivos. En tal caso, lo que se obtiene como resultado es un frente de Pareto de soluciones [2] o conjunto de soluciones no inferiores o no dominadas. De entre este conjunto de soluciones, un experto podrá elegir la que más convenga en cada caso particular y que mejor se adecua a las necesidades de la solución.

Los algoritmos de optimización combinatoria [3] se relacionan comúnmente con los problemas NP-completos. Para este tipo de problemas no existe ningún método que garantice la solución óptima en un tiempo polinomial ( $NP = \text{Nondeterministic Polynomial}$ ). Se puede decir, entonces, que los algoritmos de optimización combinatoria resuelven instancias de problemas difíciles en general, explorando el espacio de soluciones para estas instancias. Para ello, dichos algoritmos deben reducir el tamaño efectivo del espacio de soluciones, realizando así una exploración del espacio de búsqueda mucho más eficiente. De esta forma, se contemplan dos tipos de algoritmos o métodos: los métodos exactos u óptimos, que encuentran la solución óptima pero que sólo son aplicables cuando el tamaño del problema es pequeño, y los métodos aproximados o heurísticos que, aunque no garantizan el óptimo, encuentran buenas soluciones en un tiempo razonable. Dentro de los métodos exactos se encuentran las búsquedas enumerativas o de fuerza bruta y los métodos de ramificación y acotación (*Branch and Bound*). Por otro lado, algunos de los métodos aproximados más conocidos se enumeran a continuación: búsquedas heurísticas, búsquedas locales, recocido simulado, búsqueda tabú, algoritmos genéticos, algoritmos evolutivos, colonias de hormigas, etc.

En general, el método a utilizar depende de la naturaleza del problema en particular, pero también de las características esperadas de la solución. En la mayoría de las aplicaciones reales que aparecen principalmente en entornos industriales dinámicos y competitivos, la diferencia entre usar un método sencillo e inmediato, o utilizar estrategias más sofisticadas para obtener soluciones de mayor calidad, puede ser determinante

para la supervivencia de una empresa. Normalmente, los usuarios están familiarizados con el problema que van a abordar, pero no tienen por qué conocer las diferentes técnicas de resolución existentes, ni las estrategias de paralelización más convenientes. Por lo tanto, suele ser conveniente utilizar herramientas que faciliten la labor de los usuarios en la resolución del problema. Estas herramientas (esqueletos, patrones o librerías) suelen dar soporte para la técnica algorítmica a utilizar, evitando que los usuarios tengan que implementar una solución desde el comienzo.

De entre este tipo de herramientas, los esqueletos algorítmicos se presentan como un conjunto de procedimientos que constituyen el armazón con el que desarrollar programas para resolver un problema dado utilizando una técnica particular. Este software presenta declaraciones de clases vacías que el usuario ha de rellenar para adaptarlo a la resolución de un problema concreto. Los esqueletos proporcionan modularidad al diseño de algoritmos, lo que supone una gran ventaja respecto a la implementación directa del algoritmo desde el principio, no sólo en términos de reutilización de código sino también en cuanto a metodología y claridad de conceptos. El problema de estas herramientas es que la definición del problema se adapta al tipo de técnica a aplicar, con lo cual, si el usuario desea resolver el problema mediante la aplicación de técnicas diferentes, tendrá que definir el problema de formas distintas o bien implementar funciones adaptadas a cada una de las estrategias a utilizar.

Por otro lado, el diseño de software modular y reusable orientado a objetos es muy complejo. Existen técnicas para el diseño de patrones que no son nada sencillas y que no siempre obtienen la reusabilidad de los objetos esperada. El diseño de patrones está, en este sentido, muy relacionado con los esqueletos algorítmicos. Ambos pretenden obtener código modular, portable y, por supuesto, lo más reutilizable posible. Sin embargo, los patrones facilitan descripciones de objetos y clases que se adecúan para resolver problemas generales de diseño en un contexto en particular, mientras que los esqueletos algorítmicos proporcionan un mecanismo para resolver problemas aplicando un determinado tipo de técnica algorítmica. Para la implementación de este tipo de software puede utilizarse cualquier lenguaje de programación, aunque en general, los orientados a objetos son los más empleados. En la fase de diseño es preciso partir de un metamodelo, precisamente un metamodelo para problemas de optimización [4], para capturar, en términos abstractos, las características esenciales de un problema de optimización, el metamodelo puede servir como forma de almacenamiento para problemas de optimización, a partir de los cuales se pueden generar problemas de optimización reales, ejecutables.

Teniendo en cuenta todo lo anterior, en la actualidad existen diversas herramientas o marcos de trabajos conocidas como “frameworks” que ofrecen este tipo de esqueletos o librerías para optimización de problemas en base a técnicas preestablecidas. Algunos de los más conocidos son EasyLocal [5], ParadisEO [6] y ParadisEO-MOEO [7], MaLLBa [8], jMetal [9], GAMES [10], OR-Tools [11],



etc. Algunos se centran en optimización mono-objetivo y otros en optimización multi-objetivo, incluso algunas permiten hibridación de metaheurística de bajo nivel [12]. También se diferencian en el tipo de técnicas que proporcionan y en la usabilidad o dificultad de uso que presentan de cara a los usuarios finales no expertos.

Una herramienta que podría ser un punto de partida para poder abordar los objetivos plantados de este trabajo es METCO (*Metaheuristics-based Extensible Tool Cooperative Optimization*) [13]. METCO es un marco de trabajo paralelo para la resolución de problemas de optimización multi-objetivo que proporciona implementaciones de algunos de los algoritmos evolutivos y otras metaheurísticas más conocidas en el ámbito de la optimización multi-objetivo: NSGAI [14], SPEA2 [15], etc. La interfaz de METCO permite al usuario establecer características específicas del problema que necesita solucionar (representación de la solución, objetivos, operadores genéticos, etc.), pudiendo especificar una amplia gama de opciones de configuración para adaptar el comportamiento del software a varios modelos diferentes.

El reto de este trabajo sería lograr aún más separación entre el problema y las implementaciones de los resolutores. Sin embargo, las dificultades están presentes tanto en la representación del espacio de búsqueda, como en la implementación de las búsquedas dentro del mismo espacio. En la mayoría de las estrategias de búsqueda, tanto la representación del espacio de búsqueda como la forma de exploración, dependen de la implementación del propio algoritmo. Esto es, el uso de un algoritmo o estrategia de búsqueda diferente, implican una codificación de soluciones diferente y adecuada para cada caso, además de un conjunto de operadores de búsqueda adaptados para cada caso, lo cual dificulta la interacción entre el usuario y la interfaz planteada para este trabajo.

Debido a lo expuesto en el párrafo anterior, Carlos M. Fonseca [16] ha propuesto un modelo conceptual para la implementación de un software para optimización que resuelve la problemática de la separación entre el problema y los métodos de búsqueda, de tal forma que los resolutores puedan escribirse independientemente de los problemas a los que se aplicarán y que, por su parte, los problemas se puedan formular sin pensar en los operadores de búsqueda que serán empleados por los resolutores.

El diagrama de clase en la Figura 1 representa el metamodelo de la propuesta, donde podemos apreciar que la separación entre el problema y el resolutor se logra al reconocer que las estructuras del vecindario son una parte integral de la definición de problema, teniendo en cuenta que los optimizadores deben formularse en un nivel abstracto, independientemente de las estructuras vecinales específicas y, por lo tanto, de sus detalles de implementación. Este modelo ofrece una representación de la solución basada en la estructura del espacio de búsqueda y la evaluación de la solución en este espacio.

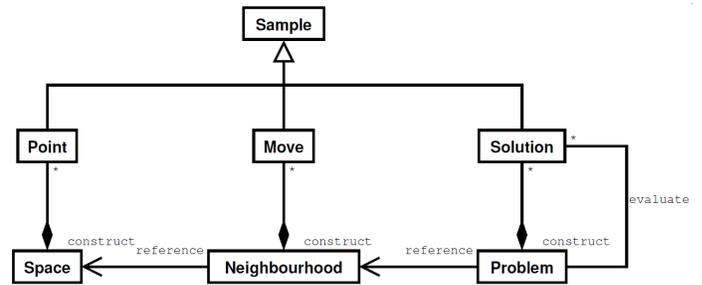


Figura 1. Diagrama de clase del Metamodelo de Carlos M. Fonseca [16]

### III. OBJETIVOS CONCRETOS E INTERÉS DE LOS MISMOS

En general, la calidad de las soluciones obtenidas al resolver un problema dependerá de la técnica algorítmica aplicada, de la eficiencia de la implementación de la técnica en cuestión, de su parametrización y, por supuesto, del conocimiento específico del problema que el usuario introduzca en el algoritmo. El proporcionar implementaciones eficientes y flexibles de técnicas algorítmicas, permite a los usuarios centrarse únicamente en el propio problema, evitándoles tener que introducirse en áreas distintas a las de su dominio. Es por lo que en este trabajo nos queremos centrar principalmente en los objetivos siguientes:

- Analizar diferentes estrategias de optimización y tipologías de problemas para definir una representación del espacio de búsqueda de forma que las operaciones de modificación de soluciones no dependan directamente de la propia estrategia a utilizar, sino que tengan una definición mucho más general y extensible a diferentes técnicas.
- Diseñar y desarrollar una herramienta que permita a los usuarios entender el esquema básico de funcionamiento de algunas de las metaheurísticas y algoritmos bio-inspirados más conocidos. Además de facilitar la comprensión de los esquemas, la herramienta también permitirá aplicar dichos esquemas a la resolución de problemas concretos y reales.
- Evitar obtener una herramienta que profundice demasiado en aspectos de implementación o en cuestiones muy particulares de cada uno de los algoritmos y que se centre en la especificación del problema a resolver.
- Incluir en la herramienta funcionalidades que permitan la especificación y configuración de algoritmos a través de una interfaz visual, intuitiva y de fácil comprensión.
- Integrar en la herramienta funcionalidades que permitan, no sólo el proceso de resolución del problema, sino también la configuración y validación de los algoritmos y de los resultados obtenidos

La hipótesis que se plantea se centra fundamentalmente en que los métodos de optimización bio-inspirados ofrecen grandes posibilidades para la resolución de problemas en el ámbito empresarial, pero debido a su complejidad intrínseca

y también a sus particularidades a la hora de configurarlos y adaptarlos a cada uno de los problemas, no se consigue extender su uso fuera del ámbito de la investigación convencional. Es por ello que se plantea la necesidad de diseñar e implementar nuevas herramientas que ayuden a mejorar la aplicabilidad de estas técnicas de optimización.

#### IV. METODOLOGÍA Y PLAN DE TRABAJO

La metodología a seguir viene dada por el método científico. En primer lugar, se llevará a cabo un exhaustivo análisis de las referencias bibliográficas relacionadas, clasificando las investigaciones para ordenar el estado del arte. Para ello se realizarán observaciones, que consisten en analizar la abundante bibliografía existente en el contexto en el que nos hemos situado. A continuación, se establecerán criterios de organización de la información seleccionada, clasificándola según su impacto, profundidad de los estudios y área de aplicación. Posteriormente, se procederá a analizar la forma actual de trabajo para detectar todas las debilidades y carencias existentes y cómo podrían ser evitadas. Una vez hecho esto, se estudiarán las distintas alternativas que puedan ayudarnos a superar estas debilidades.

Finalmente, vendrá una fase de experimentación en la que se implementarán las propuestas realizadas y se comprobará su funcionamiento tanto con bancos de pruebas como con problemas reales. Es deseable que para la fase de experimentación se utilicen algunos de los problemas más referenciados en la literatura de forma que otros investigadores puedan comprender fácilmente las aportaciones realizadas. Para demostrar o refutar la hipótesis planteada, se han de analizar los resultados obtenidos para los distintos problemas con técnicas matemáticas y estadísticas. Por último, se presentarán las conclusiones, indicando en qué condiciones las hipótesis realizadas son válidas y de utilidad.

Uno de los pilares en los que se sustenta el método científico es la reproducibilidad, es decir, la capacidad de repetir un determinado experimento. Este pilar se basa, esencialmente, en la descripción correcta y detallada de todo el entorno de experimentación y de los resultados obtenidos. Al trabajar con software informático, la reproducibilidad se ve facilitada enormemente si el mismo está disponible. Por ello, los desarrollos realizados durante esta investigación serán liberados a la comunidad científica bajo licencia GNU-GPL.

Teniendo en cuenta la metodología anterior, el plan de trabajo será el siguiente:

*Tarea 1. Revisión bibliográfica:* El objetivo de esta Tarea es abordar el estudio de los métodos, algoritmos y problemas previamente propuestos en la literatura, así como las metodologías de programación y los criterios para medir los rendimientos y calidad de las soluciones encontradas. En esta Tarea se realizará una puesta en contexto y una revisión bibliográfica. También se realizarán búsquedas en bases de datos de información relacionada. Adicionalmente, se programará la asistencia a cursos y seminarios de formación en el área.

*Tarea 2. Identificación de los recursos computacionales:* Las actividades de este proyecto requieren la utilización de recursos hardware y software especiales. Por lo tanto, será necesario la identificación de plataformas de cómputo masivo, así como la realización de una formación específica sobre su uso. De esta forma, durante el proceso de validación de la herramienta se podrá hacer un uso intensivo de recursos computacionales, acelerando así todo el proceso de análisis de las herramientas diseñadas.

*Tarea 3. Diseño y desarrollo de un software de optimización:* El software que se desarrolle deberá incorporar funcionalidades que implementen algunas de las metaheurísticas y algoritmos bio-inspirados más utilizados por la comunidad científica. Además, se prestará especial atención al proceso de configuración y validación de los algoritmos, tratando de automatizar en la medida de lo posible todo el proceso de análisis estadístico de los resultados. Una vez finalizados los desarrollos, el software será liberado, mejorando así la reproducibilidad de los resultados y haciendo accesible este tipo de técnicas al entorno empresarial.

*Tarea 4. Validación con bancos de problemas:* Las funcionalidades implementadas en la herramienta serán inicialmente comprobadas con algunos problemas de referencia de la literatura. Además, se aprovechará para generar la documentación y los tutoriales de referencia que luego sirvan para difundir la herramienta.

*Tarea 5. Aplicación a problemas reales:* La herramienta se aplicará también a problemas reales, intentando optimizarlos todo lo posible. Se compararán los resultados con los obtenidos haciendo uso de otras herramientas o marcos de trabajos existentes en la comunidad científica. En este caso, se prestará especial atención a los problemas relacionados con el ámbito de la salud. En particular, se trabajará con el problema de la planificación de menús saludables y adaptados a cada persona.

*Tarea 6. Documentación y difusión de los resultados:* El software desarrollado incluirá la documentación técnica correspondiente. Para la difusión de los resultados se utilizarán los cauces habituales de publicación en congresos y revistas.

En la Tabla I se recoge la estructura del plan de tesis y la planificación del tiempo para la ejecución de las tareas de investigación enumeradas anteriormente.

#### V. RELEVANCIA DE LA INVESTIGACIÓN

Este proyecto de tesis se integra en un Proyecto de I+D+i del Programa Estatal de Investigación, Desarrollo e Innovación orientada a los Retos de la Sociedad, titulado “*Técnicas de Optimización Meta-heurísticas Aplicadas a la Salud*” (TIN2016-78410-R). El proyecto está enfocado a realizar avances con clara aplicación de interés social de la Informática y tiene como objetivo estudiar y proponer extensiones y mejoras de modelos de optimización mono y multi-objetivo y aplicarlas a estudios relacionados con la salud. Se compararán los resultados con los obtenidos haciendo uso de otras herramientas o marcos de trabajos existentes en la comunidad científica. En este caso, se prestará especial



Cuadro I  
PLAN DE ACTIVIDADES

	1-3	4-6	7-9	10-12	13-15	16-18	19-21	22-24	25-27	28-30	31-33	34-36
Tarea 1												
Tarea 2												
Tarea 3												
Tarea 4												
Tarea 5												
Tarea 6												

Unidad de tiempo : meses

atención a los problemas relacionados con el ámbito de la salud. En particular, se trabajará con el problema de la planificación de menús saludables y adaptados a cada persona.

Además, esta investigación se enmarca en el área de la “Estrategia de Especialización Inteligente 2014-2020 (RIS3) de Canarias” [17], denominada “Agenda Digital”, en concreto, está totalmente englobada en la subárea “Crecimiento digital” pues el objetivo final de la Tesis es desarrollar una herramienta que permita que las empresas y los usuarios no expertos puedan acceder a servicios avanzados de la sociedad de la información. En concreto, se pretende hacer extensible a las empresas herramientas de optimización avanzada que permitirán gestionar de forma más eficiente los recursos disponibles en las empresas. Este es un objetivo estratégico directamente relacionado con el crecimiento digital pues, de esta forma, se podrá impulsar la competitividad y la internacionalización de nuestras empresas.

También está relacionado con la Acción COST “European Cooperation in Science and Technology”, CA15140 “Improving Applicability of Nature-Inspired Optimisation by Joining Theory and Practice” [18]. La existencia de esta acción se basa en que las estrategias de búsqueda y optimización inspiradas en la naturaleza son fáciles de implementar y de aplicar a nuevos problemas. Sin embargo, para lograr un buen rendimiento, es necesario ajustarlos al problema en cuestión y, para ello, generalmente es necesario tener un profundo conocimiento sobre el problema, pero también sobre la técnica en cuestión. Los fundamentos teóricos para la comprensión de tales enfoques se han construido con gran éxito en los últimos veinte años, pero existe una gran desconexión entre la base teórica y las aplicaciones prácticas. El desarrollo de poderosas herramientas analíticas, la comprensión significativa de las limitaciones generales de los diferentes tipos de métodos de optimización inspirados en la naturaleza y el desarrollo de perspectivas más prácticas para el análisis teórico han traído avances impresionantes al campo teórico del campo. Sin embargo, hasta ahora el impacto en el lado de la aplicación ha sido limitado y pocas personas en las diversas áreas potenciales de aplicación se han beneficiado de estos avances. Es por ello que el objetivo principal de la acción COST es cerrar esta brecha y mejorar la aplicabilidad de todo tipo de métodos de optimización inspirados en la naturaleza. Su objetivo es hacer que los conocimientos teóricos sean más accesibles y prácticos mediante la creación de una plataforma donde los teóricos y los profesionales puedan

reunirse e intercambiar ideas y necesidades, desarrollando directrices sólidas y soporte práctico para el desarrollo de aplicaciones basadas en conocimientos teóricos, desarrollando marcos teóricos impulsados por las necesidades reales que surgen de las aplicaciones prácticas, formando a los jóvenes investigadores en este campo, ampliando la participación en la investigación en curso sobre cómo desarrollar y aplicar métodos de optimización robustos inspirados en la naturaleza en diferentes áreas de aplicación.

Teniendo en cuenta lo anterior, creemos que la necesidad de desarrollar el tipo de herramientas que se plantean en esta investigación está justificado y detectado por los expertos del ámbito y, por lo tanto, sería una importante aportación para conseguir una mejora en la aplicabilidad y universalidad de este tipo de técnicas, beneficiando, no sólo a la comunidad científica involucrada sino también a potenciales usuarios y empresas que podrían gestionar más eficientemente sus recursos y procesos de producción. El hecho de que la investigación esté relacionada con el ámbito de esta acción COST supone una excelente oportunidad para que el doctorando pueda acceder a una formación muy específica y avanzada en el tema, así como para iniciar contactos y posibles colaboraciones con investigadores de reconocido prestigio en el ámbito de la optimización bio-inspirada.

#### AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto TOMAS (TIN2016-78410-R) en el marco del Plan Nacional de I+D+i del Ministerio de Economía, Industria y Competitividad, Desarrollo e Innovación orientada a los Retos de la Sociedad.

El trabajo de Moahmmmed Mahrach ha sido financiado a través del Gobierno de Canarias mediante la Agencia Canaria de investigación, Innovación y sociedad de la información, por la subvención total de la tesis titulada “Mejorando La Aplicabilidad De Metaheurísticas y Algoritmos Bio-inspirados: Aplicaciones y herramientas” en el marco del Programa Pre-doctoral de Formación del Personal Investigador mediante la ayuda con identificador TESIS2018010095.

## REFERENCIAS

- [1] Guangquan Zhang, Jie Lu, and Ya Gao. Multi-Level Decision Making. 82(4), 2015.
- [2] E Alba, B Dorronsoro, F Luna, A J Nebro C León, G Miranda, and C Segura. Metaheurísticas multiobjetivo para optimizar el proceso de difusión en MANETs metropolitanas. *Computer*, (November 2014).
- [3] Christian Blum and Andrea Roli. Metaheuristics in combinatorial optimization. *ACM Computing Surveys*, 35(3):268–308, sep 2003.
- [4] Ibrahim Assourocko and Peter Owen Denno. A metamodel for optimization problems. Technical report, 2016.
- [5] Luca Di Gaspero and Andrea Schaerf. EASYLOCAL++: an object-oriented framework for the flexible design of local-search algorithms. *Software: Practice and Experience*, 33(8):733–765, jul 2003.
- [6] S. Cahon, N. Melab, and E. G. Talbi. ParadisEO: A framework for the reusable design of parallel and distributed metaheuristics. *Journal of Heuristics*, 10(3):357–380, may 2004.
- [7] Arnaud Liefvooghe, Matthieu Basseur, Laetitia Jourdan, and El-Ghazali Talbi. ParadisEO-MOEO: A Framework for Evolutionary Multi-objective Optimization. In *Evolutionary Multi-Criterion Optimization*, pages 386–400. Springer Berlin Heidelberg, Berlin, Heidelberg, 2007.
- [8] Enrique Alba, Gabriel Luque, J. García-Nieto, G. Ordóñez, and G. Leguizamón. MALLBA: a software library to design efficient optimisation algorithms. *International Journal of Innovative Computing and Applications*, 1(1):74–85, 2007.
- [9] Juan J. Durillo and Antonio J. Nebro. jMetal: A Java framework for multi-objective optimization. *Advances in Engineering Software*, 42(10):760–771, oct 2011.
- [10] Herman De Beukelaer, Guy F Davenport, Geert De Meyer, and Veerle Fack. JAMES: A modern object-oriented java framework for discrete optimization using local search metaheuristics. In *4th International Symposium and 26th National Conference on Operational Research*, number JUNE, pages 134–138, 2015.
- [11] Google. Google Optimization Tools, 2016.
- [12] Siti Musliha Mat-rasid, Mohamad Razali Abdullah, Hafizan Juahir, Universiti Sultan, Zainal Abidin, Ahmad Bisyrri, and Husin Musawi. Research Article Special Issue. (January), 2018.
- [13] Multi-objective Optimization. Metco: a parallel plugin-based framework for multi-objective optimization. 18(4):569–588, 2009.
- [14] Kalyanmoy Deb, Amrit Pratap, Sameer Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, 2002.
- [15] Eckart Zitzler, Marco Laumanns, and Lothar Thiele. SPEA2: Improving the Strength Pareto Evolutionary Algorithm. *Evolutionary Methods for Design Optimization and Control with Applications to Industrial Problems*, pages 95–100, 2001.
- [16] C C Vieira and C M Fonseca. A unified model of optimisation problems. page 1537, 2007.
- [17] Equipo de Gestión de la RIS3 de Canarias. Estrategia de especialización inteligente de canarias 2014-2020. <https://www3.gobiernodecanarias.org/aciisi/ris3/>, Junio 2018. (Accessed on 06/19/2018).
- [18] Cost — improving applicability of nature-inspired optimisation by joining theory and practice (imappnio). [http://www.cost.eu/COST\\_Actions/ca/CA15140](http://www.cost.eu/COST_Actions/ca/CA15140), Noviembre 2015. (Accessed on 06/19/2018).



# Combinación de computación evolutiva y aprendizaje automatizado en la resolución de problemas de optimización

Doctorando: Alejandro Marrero\*,  
 Directores: Eduardo Segredo†, Coromoto León‡  
 Departamento de Ingeniería Informática y de Sistemas,  
 Facultad de Ciencias, Sección de Matemáticas,  
 Universidad de La Laguna (ULL).  
 Apartado 456 CP 38200

San Cristóbal de La Laguna. S/C de Tenerife.

Email: \*alu0100825008@ull.edu.es, †esegredo@ull.edu.es, ‡cleon@ull.edu.es

**Resumen**—En este documento se detalla el proyecto de investigación de una tesis doctoral relacionada con la computación evolutiva, el aprendizaje automatizado y su aplicación a la resolución de un subconjunto de problemas de optimización. Principalmente, se persigue el desarrollo de un modelo hiperheurístico que sea capaz de evaluar el desempeño de diversos algoritmos evolutivos multiobjetivo sobre un conjunto de instancias de un problema determinado. De este modo, cuando se presente una nueva instancia de dicho problema se pueda inferir, basándose en las características propias de dicha instancia y los resultados obtenidos previamente con instancias de similares características, qué algoritmo de los disponibles obtendría el mejor desempeño sobre esa nueva instancia dada. Asimismo, con este documento se pretende describir el trabajo que se llevará a cabo a partir de la hipótesis inicial y además, de qué manera se realizará esta investigación y cómo los resultados obtenidos pueden ser transferidos a la sociedad.

**Index Terms**—computación evolutiva, aprendizaje automatizado, optimización combinatoria.

## I. INTRODUCCIÓN

Los problemas de *optimización* pueden clasificarse en optimización discreta u optimización combinatoria y optimización continua dependiendo si las variables del problema tratado son discretas o continuas [1]. Debido a que esta investigación se centrará, principalmente, en la optimización de problemas combinatorios, serán este tipo de problemas a los que se haga referencia en el presente documento. Sin embargo, no se descarta aplicar las técnicas desarrolladas durante esta investigación a la resolución de posibles problemas de optimización continua que puedan surgir.

Cualquier problema que tenga un conjunto de soluciones discretas y una función de coste para puntuar estas soluciones respecto a las demás es un *Problema de Optimización Combinatoria (POC)*. Del mismo modo que otros problemas de optimización, el objetivo para un POC es encontrar una solución óptima al problema. Adicionalmente, un POC incluye un conjunto de restricciones que limitan el número de posibles soluciones. Las soluciones que satisfacen el conjunto

de restricciones para un problema de optimización se llaman *soluciones factibles*.

El documento continua detallando los antecedentes sobre los que se sustenta este proyecto, los objetivos fijados de la investigación, la metodología y plan de trabajo que se llevará a cabo para alcanzar dichos objetivos y, por último, la relevancia científica y la transferencia a la sociedad de este proyecto de tesis doctoral.

## II. ANTECEDENTES

En un POC, el número de posibles soluciones crece exponencialmente con el tamaño del problema  $n$  a  $O(n!)$  o  $O(e^n)$  por lo que no existe ningún algoritmo que pueda encontrar la solución óptima en un tiempo de computación polinómico [1]. Formalmente, un problema de optimización combinatoria se denota como  $(\chi, f, \Omega)$  y se formula de la siguiente forma [1]:

$$\min f(x), x \in \chi, \text{ sujeto a } \Omega$$

donde  $\chi \subset \mathbb{Z}^n$  es el espacio de búsqueda definido sobre un conjunto de  $n$  variables de decisión discretas  $x = (x_1, x_2, \dots, x_n)$ ,  $f : \chi \rightarrow \mathbb{R}$  es una función que convierte una solución dentro del espacio de búsqueda  $\chi$  en un valor entero,  $n$  es el número de variables de decisión y  $\Omega$  es el conjunto de restricciones en  $x$ . En esta definición se ha empleado una formulación de un problema de minimización, sin embargo, la formulación sería equivalente en el caso de un problema de maximización excepto por el cambio:  $\min f(x)$  por  $\max f(x)$ .

La definición proporcionada anteriormente describe la formulación de un POC mono-objetivo, es decir, únicamente existe una función objetivo a optimizar. Sin embargo, también podemos encontrar POCs multiobjetivo. En ese caso, en lugar de tener una única función objetivo a optimizar, existe en cambio un vector de funciones objetivos a optimizar. La investigación de este proyecto de tesis doctoral se centrará en la resolución de problemas de optimización combinatoria multiobjetivo, pero no exclusivamente.

Un *Problema de Optimización Combinatoria Multiobjetivo* (POM) se describe como encontrar un vector  $x$  dentro del dominio  $\chi$  de forma que optimiza el vector de funciones objetivo  $f(x)$ . Además, los distintos objetivos en un POM suelen estar en conflicto y pueden tomar direcciones distintas. Entendiendo el término dirección como *maximizar* o *minimizar*. Los objetivos en conflicto causarán que el incremento de la calidad de un objetivo tienda, simultáneamente, a decrecer la calidad de otros objetivos. Por ello, la solución a un POM no es una única solución, sino un conjunto de soluciones que representan los mejores compromisos entre los objetivos. Formalmente, la formulación de un POM es [1]:

$$\begin{aligned} \min f(x) &= (f_1(x), f_2(x), \dots, f_k(x)), x \in \chi \\ g_i(x) &\leq 0, i = 1, 2, \dots, q. \\ h_i(x) &\leq 0, i = 1, 2, \dots, p. \end{aligned}$$

donde  $x = (x_1, x_2, \dots, x_n) \in \mathbb{Z}^n$ , las funciones objetivo a optimizar  $f_i : \mathbb{Z}^n \rightarrow \mathbb{R}$ ,  $i = 1, \dots, k$  siendo  $n$  el número de variables de decisión y las funciones  $g_i : \mathbb{Z}^n \rightarrow \mathbb{R}$ ,  $i = 1, \dots, q$  y  $h_i : \mathbb{Z}^n \rightarrow \mathbb{R}$ ,  $i = 1, \dots, p$  son las funciones de restricción del problema. Aunque en esta definición solamente se presentan dos funciones de restricción  $g$  y  $h$ , el número de funciones de restricción del problema puede ser  $l \geq 1$ .

El método estándar para trabajar con un POM es el método de Pareto. Este método se basa en el principio de no-dominancia [1], [2]. En primer lugar, hay que definir el concepto de *dominancia*. El concepto de dominancia es simple. Dadas dos soluciones, ambas con puntuaciones de acuerdo a un conjunto de funciones objetivos definidas, se dice que una solución domina a otra si su puntuación es al menos de la misma calidad para todos los objetivos y, estrictamente de mejor calidad en al menos uno [2]. Formalmente, la dominancia se puede expresar como: dadas dos soluciones A y B, diremos que la solución A domina a la solución B si:

$$\begin{aligned} A \succeq B &\Leftrightarrow \forall i \in \{1, 2, \dots, n\} a_i \leq b_i, \\ & \quad y \exists i \in \{1, 2, \dots, n\}, a_i < b_i \end{aligned}$$

Cuando existen objetivos en conflicto, no existe una única solución que domine al resto de soluciones. Entonces, es cuando aparece el concepto de *no-dominancia*. La no-dominancia hace referencia a la situación en la que una solución no es dominada por ninguna otra, es decir, no se puede encontrar ninguna otra solución que mejore la calidad de algún valor objetivo sin que se empeore la calidad de otro valor objetivo de dicha solución. Las soluciones no dominadas suelen encontrarse en el límite de la región factible del espacio de búsqueda definido por el conjunto de funciones de restricción del problema tratado. Este conjunto de soluciones no dominadas se suele llamar generalmente conjunto de Pareto [1].

Hoy en día, existe un gran abanico de posibilidades en cuanto a técnicas de optimización. Como se puede apreciar en

la Figura 1, los algoritmos de optimización se pueden dividir en *métodos exactos* y *métodos aproximados*.

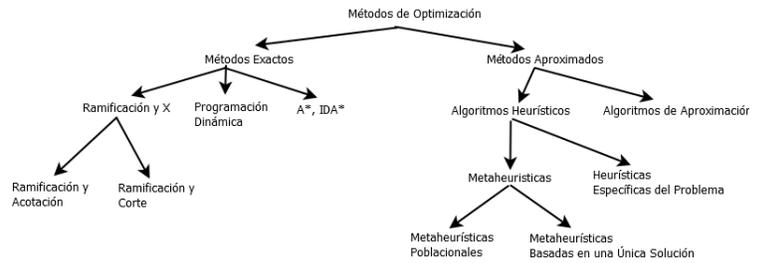


Figura 1. Métodos de optimización.

Por un lado, los algoritmos exactos son aquellos que se caracterizan, principalmente, porque obtienen la solución óptima, si existe, al problema para el que se emplean. Sin embargo, este no será el campo de estudio de este proyecto de tesis doctoral. Por otro lado, están los algoritmos aproximados que a diferencia de los métodos de optimización exactos, permiten obtener soluciones factibles a problemas complejos en un tiempo aceptable, aunque no garantizan obtener la solución óptima global [3]. A pesar de esto, en los últimos años estas técnicas algorítmicas han ganado una gran popularidad dado que han demostrado su efectividad y eficiencia en muchos campos y con una gran cantidad de problemas distintos [4]–[6]. Los algoritmos aproximados se pueden subdividir principalmente en heurísticas, metaheurísticas e hiperheurísticas. Las palabras *meta* y *heurística* tienen su origen en la antigua Grecia: *meta* significa ‘nivel superior’ y *heurística* denota el arte de descubrir nuevas estrategias [1]. Las heurísticas son técnicas basadas en la experiencia para la resolución de problemas y el aprendizaje [1], [2]. El término metaheurísticas fue acuñado en 1986 por Glover para hacer referencia a un conjunto de técnicas conceptualmente posicionadas encima de las heurísticas en el sentido que estas guiaban el diseño de las heurísticas [1], [2]. En esencia, una metaheurística es un procedimiento de alto nivel o heurística diseñada para encontrar, generar o seleccionar un procedimiento de bajo nivel o heurística que pueda proporcionar una solución suficientemente buena a un problema de optimización. Además, dentro del conjunto de metaheurísticas existentes, podemos encontrar metaheurísticas poblacionales o metaheurísticas basadas en una única solución. Esta nueva clasificación discierne entre algoritmos que emplean una única solución que será modificada con cada iteración del algoritmo hasta el final de su ejecución de los algoritmos que emplean un conjunto de  $m \geq 2$  soluciones factibles que son modificadas hasta que la condición de parada sea alcanzada.

Por último, la idea de hiperheurísticas apareció a principios de los años 60. Las hiperheurísticas se pueden ver como técnicas heurísticas que permiten seleccionar o generar (meta) heurísticas. Una hiperheurística es un método de búsqueda heurístico que persigue automatizar el proceso de seleccionar, combinar, generar o adaptar varias heurísticas o metaheurísti-



cas para resolver problemas complejos eficientemente. Al contrario que las metaheurísticas, las hiperheurísticas no trabajan sobre el espacio de búsqueda del problema tratado sino que siempre lo hacen sobre el espacio de búsqueda de heurísticas o meta-heurísticas del nivel inferior. Asimismo, las hiperheurísticas de generación se pueden basar en la programación genética o evolución gramatical [1], [2].

Adicionalmente, existe un conjunto de técnicas de optimización dentro de un marco denominado *Computación Evolutiva (CE)* que trata de sintetizar el comportamiento de la naturaleza o la interacción entre ciertas especies de animales y aplicar estos comportamientos a la resolución de problemas de optimización [2]. La metáfora fundamental sobre la que se sustenta el campo de la CE es el poder de la evolución natural y su particular estilo para solventar problemas, el método de prueba y error.

Si consideramos la evolución natural como la existencia de un entorno determinado en el que conviven individuos de una determinada población que buscan su supervivencia, podríamos denominar las aptitudes de cada uno de los individuos de la población como su calidad o *fitness* para determinar la posibilidad de supervivencia y reproducción de cada uno de ellos. Así pues, en el marco de la resolución de problemas, el entorno sería el problema tratado y la población de individuos estaría representada por un conjunto de soluciones factibles al problema dónde cada una de ellas posee un valor de calidad que determinará su “supervivencia” y la posibilidad de que sean empleadas como semillas para obtener nuevas soluciones candidatas.

Actualmente existen diversas variantes de algoritmos evolutivos aunque se puede destacar principalmente las siguientes categorías:

- Algoritmos Genéticos [7]–[9].
- Estrategias Evolutivas [10], [11].
- Evolución Diferencial [12]–[15].

Dado que la investigación de este proyecto de tesis doctoral se centrará en la resolución de problemas multiobjetivo, cabe hacer especial mención al estado del arte en cuanto a algoritmos evolutivos multiobjetivo, centrándose en aquellos aplicados a la resolución de problemas de optimización combinatoria multiobjetivo.

A la hora de resolver un problema de optimización combinatoria multiobjetivo, se puede hacer uso de diversos algoritmos evolutivos multiobjetivo (Multiobjective Evolutionary Algorithms - MOEAs) como pueden ser entre otros:

- Multiobjective Genetic Algorithm (MOGA) [2], [16].
- Non-dominated Sorting Genetic Algorithm (NSGA) [2], [16].
- Non-dominated Sorting Genetic Algorithm II (NSGA-II) [2], [16].
- Niche Pareto Genetic Algorithm (NPGA) [2], [16].
- Strength Pareto Evolutionary Algorithm (SPEA-2) [2], [16].
- Pareto Archived Evolutionary Strategy (PAES) [2], [16].
- Indicator-Based Evolutionary Algorithm (IBEA) [17].

Sin embargo, hay que tener en cuenta que probar el rendimiento de estos algoritmos requiere realizar experimentos computacionales con varias instancias distintas del mismo problema tratado. Por lo tanto, el desempeño de estos algoritmos se puede ver afectado por la idiosincrasia de la instancia del problema tratado, y elegir un único algoritmo para optimizar todas las instancias de un determinado problema puede no ser eficiente. Es entonces, cuando la aplicación del aprendizaje automatizado o *Machine Learning (ML)* aparece.

El término aprendizaje automatizado implica la construcción de modelos matemáticos para ayudar a entender los datos [18]. El aprendizaje entra en escena cuando se proporciona a estos modelos parámetros modificables que pueden ser adaptados a partir de los datos observados [18]. Dentro del término aprendizaje automatizado se pueden encontrar también varias categorías en función del tipo de aprendizaje empleado para el modelo desarrollado:

- Aprendizaje Supervisado (*Supervised Learning*): un modelo con aprendizaje supervisado es entrenado con un conjunto de datos de entrenamiento hasta alcanzar un cierto umbral de acierto y posteriormente pasa a un estado de validación con un conjunto de datos distinto. En ese momento, el modelo puede ser empleado con un nuevo conjunto de datos distinto al utilizado en las fases de entrenamiento y validación [18].
- Aprendizaje no Supervisado (*Unsupervised Learning*): el aprendizaje no supervisado implica obtener las características del conjunto de datos sin tener referencias previas [18].
- Aprendizaje Semi-supervisado (*Semi-supervised Learning*): esta aproximación se encuentra a medio camino entre el aprendizaje supervisado y el aprendizaje no supervisado y suele ser útil cuando sólo se tienen unas pocas referencias previas [18].
- Aprendizaje por Refuerzo (*Reinforcement Learning*): el aprendizaje por refuerzo se basa en aprender continuamente de las tareas realizadas para posteriormente poder determinar el comportamiento idóneo en un contexto específico para maximizar su rendimiento [19].

Además de lo explicado anteriormente, el aprendizaje automatizado se puede clasificar en diversos paradigmas. Este proyecto de tesis doctoral se orientará al paradigma denominado *Lifelong Machine Learning o Lifelong Learning (o Aprendizaje Permanente)*. El aprendizaje permanente es una técnica avanzada de aprendizaje automatizado que se caracteriza porque los modelos construidos bajo esta filosofía aprenden continuamente, acumulan conocimiento adquirido de las tareas previas y lo usan para las futuras tareas a realizar [20], [21].

Las aplicaciones generales del aprendizaje automatizado junto con la computación evolutiva suele tener como objetivo aumentar el desempeño de algoritmos evolutivos para aprovechar el conocimiento adquirido a lo largo de la ejecución de un experimento computacional y así incrementar la eficiencia de los resultados finales [22]–[24].

‘Combinación de computación evolutiva y aprendizaje automatizado en la resolución de problemas de optimización’

es un proyecto de tesis doctoral que propone la unión de algoritmos metaheurísticos basados en la CE y el ML [25] para la resolución de problemas de optimización combinatoria multiobjetivo. No obstante, este proyecto de tesis doctoral no pretende seguir las aproximaciones convencionales que desarrollan el resto de estudios del campo sino que, persigue el desarrollo de un modelo hiperheurístico que sea capaz de evaluar el desempeño de diversos algoritmos evolutivos multiobjetivo sobre un conjunto de instancias de un problema determinado. De este modo, cuando se presente una nueva instancia de dicho problema se pueda inferir, basándose en las características propias de dicha instancia y los resultados obtenidos previamente con instancias de similares características, qué algoritmo de los disponibles obtendría el mejor desempeño sobre esa nueva instancia dada.

Por último, el desarrollo del modelo hiperheurístico se realizará en lenguaje de programación Python. Si bien existen numerosos lenguajes de programación que proporcionan herramientas de desarrollo de aprendizaje automatizado y módulos matemáticos, Python se ha convertido en el lenguaje más empleado en la actualidad debido a la gran cantidad de módulos que proporciona, su sencillez y fiabilidad. La combinación de estas características han convertido a Python en el nuevo lenguaje de la *computación científica* para la resolución de problemas como: simulaciones numéricas, modelos apropiados y análisis de datos y optimización.

### III. OBJETIVOS

Concretamente, el objetivo principal y subobjetivos de este proyecto de tesis doctoral son:

- Desarrollar una herramienta que incluya un modelo hiperheurístico de aprendizaje permanente haciendo uso de las herramientas de aprendizaje automatizado proporcionadas en el lenguaje Python [18], [20], [26].
  1. Implementar el modelo hiperheurístico con diversos tipos de aprendizaje:
    - a) Aprendizaje Supervisado.
    - b) Aprendizaje por Refuerzo.
  2. Generar gráficos con los resultados que apoyen los resultados obtenidos.
  3. Generar informes del proceso realizado por el modelo.
  4. Integrar el modelo con una herramienta que proporcione algoritmos evolutivos multiobjetivo y problemas de optimización combinatoria para poder realizar experimentos computacionales.

Para la realización de experimentos computacionales y testeo del modelo hiperheurístico desarrollado se trabajará sobre problemas académicos y problemas reales. Con respecto al marco académico, se trabajará con problemas ampliamente estudiados como el problema del Viajante de Comercio (*Travelling Salesman Problem - TSP*), el problema de la Mochila Multidimensional Multiobjetivo (*Multidimensional Multiobjective Knapsack Problem - MMKP*) [27]–[29], entre otros. En cambio, en el marco de la aplicación a problemas reales, se

estudiarán problemas relacionados con el área de la nutrición dentro del proyecto *Meta-heuristics for the Optimisation of Resources and Problems in Health* en el que trabaja el grupo de investigación de Algoritmos y Lenguajes Paralelos de la Universidad de La Laguna.

### IV. METODOLOGÍA Y PLAN DE TRABAJO

Durante el desarrollo de este proyecto de tesis doctoral se diferenciará entre la metodología general de investigación seguida y la metodología empleada para el desarrollo del software del modelo hiperheurístico.

La metodología de investigación que se seguirá para el desarrollo de esta tesis doctoral se basa en las referencias tomadas de [30]–[32]. La metodología seguida será la de una investigación cuantitativa con experimentos computacionales marcada por las siguientes fases:

1. Fase conceptual: esta fase inicial se subdivide en las siguientes subfases:
  - a) Formulación y delimitación del problema a tratar.
  - b) Revisión de la literatura asociada.
  - c) Construcción del marco teórico.
  - d) Formulación de Hipótesis.
2. Fase de formulación y diseño: fase en la que se definirán los experimentos a realizar:
  - a) Selección de un conjunto de instancias del problema tratado para estudiar.
  - b) División del conjunto de instancias en diferentes subconjuntos en función del tipo de aprendizaje empleado por el modelo.
  - c) Diseño de los experimentos.
3. Fase empírica: incluye los siguientes procesos:
  - a) Realización de los experimentos diseñados.
  - b) Recolección de datos (resultados de los experimentos realizados).
  - c) Preparación de los datos para realizar un análisis.
4. Fase analítica: comprende los procesos de análisis de los resultados obtenidos:
  - a) Análisis de datos.
  - b) Interpretación de los resultados del análisis.
5. Fase de difusión: esta fase esta destinada a la redacción y publicación de la investigación realizada.

Por otro lado, metodología para el desarrollo del modelo hiperheurístico, se basará en las directrices de metodologías de desarrollo de software ágiles, la metodología de desarrollo software guiado por pruebas (Test-Driven Development-TDD) [26], [33], [34], los principios SOLID [35] de la programación orientada a objetos y la filosofía de código abierto. Además, el seguimiento del correcto funcionamiento de la herramienta desarrollada se corroborará con la utilización de la plataforma Travis-CI<sup>1</sup> para integración continua.

Si bien poner práctica estas metodologías y directrices pueden ralentizar ligeramente el proceso de desarrollo de software, su aplicación ayuda enormemente al mantenimiento

<sup>1</sup><https://travis-ci.org/>



del software desarrollado así como a reducir el número de posibles errores de codificación dentro del programa [26].

Hoy por hoy, existen diversos entornos y herramientas que implementan multitud de algoritmos heurísticos y metaheurísticos para la resolución de problemas mono-objetivos y multiobjetivos en diversos lenguajes de programación como pueden ser: JMetal [36], [37], HeuristicLab [38], ParadiseO [39], etc. No obstante, la herramienta seleccionada para la realización de experimentos computacionales en esta investigación será la denominada Metaheuristic-based Extensible Tool for Cooperative Optimisation (METCO) [40].

En lo que respecta al plan de trabajo para este proyecto, se diseñará considerando los objetivos SMART [41], [42], siglas en inglés para específico, medible, alcanzable, relevante y con tiempo limitado (*Specific-Measurable-Attainable-Realistic-Timely*). Por ello, se definirán las tareas a realizar dentro de un espacio de cuatro años con una dedicación a tiempo completo. Así, el plan de trabajo propuesto se compone de las siguientes tareas y subtareas:

1. Estudiar el estado del arte de los tópicos tratados en este proyecto:
  - a) Aprendizaje permanente.
  - b) Aprendizaje Supervisado y Aprendizaje por Refuerzo.
  - c) Algoritmos Evolutivos Multiobjetivo.
  - d) Problemas académicos y reales enumerados en la sección III.
2. Implementar uno de los problemas académicos en la herramienta METCO.
3. Implementar uno de los problemas reales en la herramienta METCO.
4. Recabar instancias del problema desarrollado, preferiblemente ya usadas en algún estudio previo para contrastar los resultados obtenidos.
5. Experimentación computacional inicial con el objetivo de obtener los resultados iniciales para el modelo.
  - a) Diseño del experimento: instancias a emplear, algoritmos que se probarán y parametrización de los algoritmos.
  - b) División del conjunto de instancias en dos conjuntos: entrenamiento y validación.
  - c) Ejecución del experimento para obtener los resultados iniciales.
6. Análisis de los resultados experimentales iniciales.
  - a) Recolección de los resultados experimentales.
  - b) Análisis de los resultados obtenidos mediante un test estadístico.
  - c) Interpretación de los resultados obtenidos.
7. Desarrollo del modelo hiperheurístico en Python:
  - a) Definición del formato que deben tener los ficheros de las instancias y resultados que se van a emplear.
  - b) Desarrollo del modelo hiperheurístico con aprendizaje supervisado.
  - c) Desarrollo del modelo hiperheurístico con aprendizaje por refuerzo.
  - d) Desarrollo de un módulo que permita obtener gráficos que soporten las conclusiones obtenidas por el modelo.
  - e) Desarrollo de informes generados por el proceso realizado por el modelo.
8. Experimentación computacional con el modelo hiperheurístico y METCO.
  - a) Diseño del experimento: nuevas instancias a emplear.
  - b) Ejecución del experimento.
9. Análisis de los resultados experimentales.
  - a) Recolección de los resultados experimentales.
  - b) Análisis de los resultados obtenidos mediante un test estadístico.
  - c) Interpretación de los resultados obtenidos
10. Desarrollo de la documentación relativa al software desarrollado:
  - a) Generar la documentación del software en formato PDF, HTML y Markdown.
  - b) Crear un tutorial de uso de la herramienta en formato PDF, HTML y Markdown.
11. Redacción de la memoria de la tesis doctoral. Este proceso, aunque se incluye en último lugar, será realizado de manera incremental tras finalizar cada una de las tareas precedentes.

Especialmente, la consecución de las tareas 2, 3, 7, 8 y 9 representan los hitos que van a marcar el cumplimiento de los objetivos propuestos en la sección III.

## V. RELEVANCIA

Desde el punto de vista de la relevancia que puede tener este proyecto de tesis doctoral, podríamos destacar por un lado que, a nivel científico, supondría un cambio en la tendencia en el campo de investigación con respecto a la aplicación de técnicas de aprendizaje automatizado junto con algoritmos de Computación Evolutiva para la resolución de problemas de optimización.

Además, los problemas académicos con los que se trabajará en este proyecto de tesis doctoral no han sido resueltos aplicando este enfoque por lo que se aportaría nuevos resultados de gran interés como base para nuevas investigaciones.

Por otro lado, los problemas académicos tratados tienen una aplicación casi directa al mundo real. Por ejemplo, el problema MMKP tiene muchas aplicaciones en el ámbito industrial, social y logístico. Asimismo, el modelo matemático que define el problema MMKP puede ser extraído a otros problemas existentes como por ejemplo el problema de la planificación de menús [43]. De igual manera, el empleo de las técnicas desarrolladas al proyecto *Meta-heuristics for the Optimisation of Resources and Problems in Health* proporcionará una aplicación directa a la sociedad.

Es por ello, que la obtención de resultados relevantes acerca de los problemas académicos tratados, y el proyecto *Meta-heuristics for the Optimisation of Resources and Problems in Health* así como la finalización exitosa de este proyecto de

tesis doctoral, puede conducir a nuevos y mejores resultados no sólo de estos problemas, sino de otros problemas con similar formulación matemática, y por consiguiente a la mejora de procesos industriales y factores sociales.

#### AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Economía, Industria y Competitividad dentro del programa 'I+D+i Orientada a los Retos de la Sociedad' con referencia de proyecto TIN2016-78410-R.

#### REFERENCIAS

- [1] K.-L. Du and M. N. S. Swamy, *Search and Optimization by Metaheuristics: Techniques and Algorithms Inspired by Nature*, 1st ed. Birkh&#228;user Basel, 2016.
- [2] A. E. Eiben and J. E. Smith, *Introduction to Evolutionary Computing*. SpringerVerlag, 2003.
- [3] E.-G. Talbi, *Metaheuristics*, 1st ed. Wiley, 2009.
- [4] L. Antonio, J. Berenguer, and C. Coello, "Evolutionary many-objective optimization based on linear assignment problem transformations," *Soft Computing*, pp. 1–22, 2018, cited By 0; Article in Press.
- [5] M. Köksalan and D. Tezcaner Öztürk, "An evolutionary approach to generalized biobjective traveling salesperson problem," *Computers and Operations Research*, vol. 79, pp. 304–313, 2017, cited By 0.
- [6] W. Mashwani and A. Salhi, "Multiobjective evolutionary algorithm based on multimethod with dynamic resources allocation," *Applied Soft Computing Journal*, vol. 39, pp. 292–309, 2016, cited By 2.
- [7] D. Whitley, "A genetic algorithm tutorial," *Statistics and Computing*, 1994.
- [8] P. G. Algorithms, S. Edition, R. Haupt, and S. Haupt, "The continuous genetic algorithm," *Practical Genetic Algorithms, Second . . .*, 2004.
- [9] S. Sivanandam and S. Deepa, "Genetic Algorithm Implementation Using Matlab," *Introduction to Genetic Algorithms*, 2008.
- [10] H.-g. Beyer and H.-p. Schwefel, "Evolution strategies," *Evolutionary Computation*, 2002.
- [11] N. Hansen, "CMA-ES Python package," 2017.
- [12] T. Algorithm, "Differential Evolution," *Evolution*, 2006.
- [13] L. Zheng, S. Zhang, K. Tang, and S. Zheng, "Differential evolution powered by collective information," *Information Sciences*, vol. 399, pp. 13–29, 2017, cited By 0.
- [14] C. Fu, C. Jiang, G. Chen, and Q. Liu, "An adaptive differential evolution algorithm with an aging leader and challengers mechanism," *Applied Soft Computing Journal*, vol. 57, pp. 60–73, 2017, cited By 0.
- [15] M. Tian, X. Gao, and C. Dai, "Differential evolution with improved individual-based parameter setting and selection strategy," *Applied Soft Computing Journal*, vol. 56, pp. 286–297, 2017, cited By 0.
- [16] A. Zhou, B.-Y. Qu, H. Li, S.-Z. Zhao, P. N. Suganthan, and Q. Zhang, "Multiobjective evolutionary algorithms: A survey of the state of the art," *Swarm and Evolutionary Computation*, vol. 1, no. 1, pp. 32 – 49, 2011.
- [17] E. Zitzler and S. Künzli, "Indicator-based selection in multiobjective search," in *Parallel Problem Solving from Nature - PPSN VIII*, X. Yao, E. K. Burke, J. A. Lozano, J. Smith, J. J. Merelo-Guervós, J. A. Bullinaria, J. E. Rowe, P. Tiño, A. Kabán, and H.-P. Schwefel, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004, pp. 832–842.
- [18] J. VanderPlas, *Python Data Science Handbook: Essential Tools for Working with Data*, 1st ed. O'Reilly Media, Inc., 2016.
- [19] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey," *CoRR*, vol. cs.AI/9605103, 1996.
- [20] Z. Chen and B. Liu, *Lifelong Machine Learning*. Morgan & Claypool Publishers, 2016.
- [21] D. Silver, Q. Yang, and L. Li, "Lifelong machine learning systems: Beyond learning algorithms," 03 2013.
- [22] J. Zhang, Z.-h. Zhang, Y. Lin, N. Chen, Y.-j. Gong, J.-h. Zhong, H. Chung, Y. Li, and Y.-h. Shi, "Evolutionary computation meets machine learning: A survey," *Comp. Intell. Mag.*, vol. 6, no. 4, pp. 68–75, Nov. 2011.
- [23] M. Yoshida, T. Hinkley, S. Tsuda, Y. M. Abul-Haija, R. T. McBurney, V. Kulikov, J. S. Mathieson, S. Galinanes Reyes, M. D. Castro, and L. Cronin, "Using evolutionary algorithms and machine learning to explore sequence space for the discovery of antimicrobial peptides," *Chem*, vol. 4, no. 3, pp. 533–543, mar 2018.
- [24] B. Moradi, "An intelligent evolutionary computation approach for solving the shortest path problem," *Journal of Multiple-Valued Logic and Soft Computing*, vol. 30, no. 4-6, pp. 335–357, 2018, cited By 0.
- [25] M. Gimenez Fayos, "Una aproximacion basada en aprendizaje automatico para diversos problemas de procesamiento de lenguaje natural en redes sociales," 2016.
- [26] M. Kirk, *Thoughtful Machine Learning with Python: A Test-Driven Approach*, 2nd ed. O'Reilly Media, Inc., 2017.
- [27] K. Florios, G. Mavrotas, and D. Diakoulaki, "Solving multiobjective, multiconstraint knapsack problems using mathematical programming and evolutionary algorithms," *European Journal of Operational Research*, vol. 203, no. 1, pp. 14–21, 2010.
- [28] T. Lust and J. Teghem, "The multiobjective multidimensional knapsack problem: A survey and a new approach," *International Transactions in Operational Research*, vol. 19, no. 4, pp. 495–520, 2012.
- [29] N. Abboud, M. Sakawa, and M. Inuiguchi, "A fuzzy programming approach to multiobjective multidimensional 0-1 knapsack problems," *Fuzzy Sets and Systems*, vol. 86, no. 1, pp. 1–14, 1997.
- [30] S. Rajasekar, P. Philominathan, and V. Chinnathambi, "Research Methodology," pp. 1–53, 2006.
- [31] H. Hassani, "Research methods in computer science: The challenges and issues," *CoRR*, vol. abs/1703.04080, 2017.
- [32] C. A. Monje Álvarez, "Metodología de la investigación cuantitativa y cualitativa. Guía didáctica." *Universidad Surcolombiana*, pp. 1–216, 2011.
- [33] C. Desai, D. Janzen, and K. Savage, "A survey of evidence for test-driven development in academia," *SIGCSE Bull.*, vol. 40, no. 2, pp. 97–101, Jun. 2008.
- [34] W. Bissi, A. Neto, and M. Claudia Figueiredo Pereira Emer, "The effects of test driven development on internal quality, external quality and productivity: A systematic review," vol. 74, 02 2016.
- [35] H. Singh and S. I. Hassan, "Effect of solid design principles on quality of software: An empirical assessment," vol. 6, 04 2015.
- [36] J. J. Durillo and A. J. Nebro, "jmetal: A java framework for multi-objective optimization," *Advances in Engineering Software*, vol. 42, pp. 760–771, 2011.
- [37] J. Durillo, A. Nebro, and E. Alba, "The jmetal framework for multi-objective optimization: Design and architecture," in *CEC 2010*, Barcelona, Spain, July 2010, pp. 4138–4325.
- [38] S. Wagner, G. Kronberger, A. Beham, M. Kommenda, A. Scheibenpflug, E. Pitzer, S. Vonolfen, M. Kofler, S. Winkler, V. Dorfer, and M. Affenzeller, *Advanced Methods and Applications in Computational Intelligence*, ser. Topics in Intelligent Engineering and Informatics. Springer, 2014, vol. 6, ch. Architecture and Design of the HeuristicLab Optimization Environment, pp. 197–261.
- [39] S. Cahon, N. Melab, and E.-G. Talbi, "Paradiseo: A framework for the reusable design of parallel and distributed metaheuristics," *Journal of Heuristics*, vol. 10, no. 3, pp. 357–380, May 2004.
- [40] C. León, G. Miranda, and C. Segura, "Metco: A parallel plugin-based framework for multi-objective optimization," *International Journal on Artificial Intelligence Tools*, vol. 18, no. 04, pp. 569–588, 2009.
- [41] G. T. Doran, "There's a S.M.A.R.T. way to write managements's goals and objectives," *Management Review*, vol. 70, no. 11, pp. 35–36, 1981.
- [42] C. Fuhrmann, J. Hobin, P. S. Clifford, and B. Lindstaedt, "Goal-setting strategies for scientific and career success," 12 2013.
- [43] B. K. Seljak, "Computer-based dietary menu planning," *Journal of Food Composition and Analysis*, vol. 22, no. 5, pp. 414–420, 2009.

# *Classification system for the predicting of psychosocial risk level in public-school teachers based on Artificial Intelligence*

*Rodolfo Mosquera Navarro, Ph.D(c)*

*Industrial Engineering Department, Faculty of Engineering  
National University of Colombia  
Manizales, Colombia  
[rmosqueran@unal.edu.co](mailto:rmosqueran@unal.edu.co)*

*Director: Omar Danilo Castrillon Gómez, Ph.D*

*Industrial Engineering Department, Faculty of Engineering  
National University of Colombia  
Manizales, Colombia  
[odcastrillong@unal.edu.co](mailto:odcastrillong@unal.edu.co)*

*Co-director: Liliana Parra Osorio, Ph.D*

*Psychosocial and Work Organization Department  
Universidad Libre, Bogotá  
Bogotá, Colombia  
[lilianaparraosorio@hotmail.com](mailto:lilianaparraosorio@hotmail.com)*

*Co-director: Andrés Carrión García, Ph.D*

*Director - Master Program in Data Analysis Engineering  
Polytechnical University of Valencia  
Valencia, Spain  
[acarrion@eio.upv.es](mailto:acarrion@eio.upv.es)*

**Abstract**— A new method to identify psychosocial risk level classification in Colombian public-school teachers, based on new hybrid approach on Artificial Intelligence. In this paper, we propose a first approach to hybrid prediction method using the algorithm hill climbing and Support Vector Machines (HC-SVM) to predict the psychosocial risk level on Colombian teachers public-schools in the metropolitan area of a Colombian city, where uses HC to optimize the input parameters of the prediction model based on SVM. A database with 5,340 epidemiological records that correspond to the psychosocial evaluations of public-school teachers in the metropolitan area of a Colombian city (five municipalities). In the best classification performance, general precision and stability will obtained with 95% effectiveness compared to the psychosocial clinical diagnosis. Three new physiological variables will be implemented to be associated with psychosocial risk levels (heart rate, skin electrodermal activity, and electromyography). To validate the proposed prediction method, a 480 individuals who were representative of the sample will randomly chosen and evaluated with three new physiological variables is selected as a case study. Use of the model as an instrument for prediction of psychosocial risk level in public-school teachers is suggested as a tool for occupational psychologists to improve psychosocial risk prevention programs within administrative and occupational safety systems.

**Keywords**— *Support vector machine; hill climbing; psychosocial risk level; management; work organization; public-school teachers.*

## I. INTRODUCTION

The International Labor Organization (ILO), defines stress as the physical and emotional response to an event caused by the lack of balance between the perceived demands and perceived resources and capabilities that an individual has to cope with said demands. Work-related stress is determined by

the work relationships, job design, and work organization. It presents when work demands are not commensurate with, do not coincide with the company's organizational and functional culture expectations [1].

The problems, which have been reported in the workplace, as well as the occupational hazards that require the most urgent attention include: injury and accident prevention, followed by psychosocial risks, work-related stress and musculoskeletal disorders. Action priorities regarding workplace health and safety point clearly to the need to build capacity for and generate instruments, which permit epidemiological surveillance of psychosocial risk and work-related stress. Proposed solutions include a redefinition of tools that facilitate risk identification and control [2].

In Colombia, relating to psychosocial risk, the second national survey for workplace health and safety conditions in the Colombian general occupational risk system indicates that almost 12% of workers' cognitive performance and confrontation abilities are affected, which demonstrates the need for further research on development strategies for accident prevention, health promotion and illness prevention [3].

Certain studies carried out in human resource management areas, in fields where psychosocial risk appears in particular variables as a part of organizational management and the work environment, show the effectiveness of using support vector machines for detection of an employee's intention to quit, associating work motivation, job satisfaction, and stress levels as predictors [4]. They have also been useful in studies related to prediction of voluntary employee turnover associated with job performance [5].

The large number of variables utilized in the identification of psychosocial risk (predictors) and various variables (classes) makes important the recognition of the variables that impact on

---

We extend our sincere thanks to the "Convocatoria Nacional para el Apoyo al Desarrollo de Tesis de Posgrado o de Trabajos Finales de Especialidades en el área de la Salud de la Universidad Nacional de Colombia 2017-2018" via Resolution 21 of 2017 from the office of the Vice-rector of Investigation (21 of December 2017), for selecting this proposal for project financing with identification number 40976.

the risk on people and can be recognized through of the so-called methods for supervised pattern recognition (classification methods). The classification methods are used in different fields, including cellular biology using SVM's [6], image analysis using Support Vector Machines least squares (LS-SVM) [7], fault detection and diagnosis of an industrial steam turbine industrial process using support vector machine (SVM) and adaptive neuro-fuzzy inference system (ANFIS) [8], fault detection and diagnosis in process data using one-class support vector machines [9], and in various aspects of economics as time series prediction [10].

In this investigation, the HC-SVM model is used for psychosocial risk level prediction in public-school teachers. The rest of this article is organized as follows: Section 2 summarizes the prediction model, Section 3 addresses a numerical example taken from evaluations performed on public-school teachers from five Colombian municipalities, and finally, conclusions are presented in Section 4.

## II MATERIALS AND METHODS

This section presents short descriptions of the models, which compose the new hybrid method, information from the database used, as well as an explanation of implementation of the model in the present study.

### A. Support Vector Machine (SVM) background algorithm

Support Vector Machines (SVM), proposed by [11], are a supervised machine learning approach. Support vector machines have an advantage over other existing classification approaches, in that they provide a global solution for data classification [12][13]. They generate a unique global hyperplane in order to separate data points from different classes, instead of local limits, as compared to other existing data classification approaches. As support vector machines follow the principal of Structural Risk Minimization (SRM), they reduce the appearance of risk during the training phase [14].

Support vector machines attempt to find an optimum decision limit, or to maximize the margin, by finding the greatest achievable distance between the separating hyperplane and the data points either side [15]. Data classification may be represented through consideration of a group of ordered pair values  $D = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_l, Y_l)\}$ , where  $i = 1, \dots, 5340$ . Here,  $x \in X$  and  $y \in Y$  where 'Y' represents the class label (Risk level), for example, in the binary classification  $Y = \{-1, +1\}$ . If the classes are not linearly separable, owing to data out of range (data uncertainty, etc.), it is still possible to use the linear classifier with error tolerance. In this case, the objective is to find a balance between maximizing data accuracy and minimizing error.

### B. Hill Climbing

The local random restart search is carried out through random selection of an initial solution (in other words, it is

uniformly generated in the solution space), and a local deterministic search is applied (moving iteratively to the best neighbor of the current solution) until a local optimal is found.

This process is repeated until  $k$  local optimals are obtained. The best of these  $k$  local optimals are compared each time that an iteration is performed. The local search (LS) performs a macro iteration (restart), in which the neighbor function  $\eta$  is defined such that the solution space is attainable.

Hill climbing variables  $R_k(w(i), w) = 0$  for all  $w(i) \in \Omega, w \in \eta(w(i))$  and the best neighbor solution are selected in each internal iteration. Once a  $G \cup L$  element is found, a new  $\Omega$  element is randomly generated (uniformly) in order to begin the next group of iterations (internal loop) [16].

### C. Data used

The group of data comes from a database of information collected from evaluations performed on 5,340 public-school teachers in the metropolitan area of a Colombian city. Said information consists of sociodemographic data, organizational, environmental, physical, and psychosocial variables, which contain 123 predicting variables and one class variable, as shown in Table 1. The model were trained using the same group of training data, 80% training set  $X_{ij}$  and 20% validation set  $V_{ij}$ .

TABLE I. VARIABLES FOR DOMAINS ON INTRALABORAL PSYCHOSOCIAL RISK FACTORS. ADAPTED FROM: BATTERY FOR EVALUATION OF PSYCHOSOCIAL RISK FACTORS. [17] ANNEX 1.

Items	Domains	Variables
$S_i$	Sociodemographic	$S_1 \dots S_{10}$
$D_i$	Work demands	$D_1 \dots D_{50}$
$W_i$	Work control	$W_1 \dots W_{21}$
$L_i$	Leadership and social relations in the workplace	$L_1 \dots L_{32}$
$R_i$	Rewards	$R_1 \dots R_{11}$

### D. Sample data with new physiological variables

A random sample of 480 individuals, who decided to participate voluntarily, was extracted. New physiological variables were added (Hearth rate, skin electrodermal activity, and electromyography), which consisted of 130 variables, 129 of which were independent, and one which was dependent.

### E. Hierarchical cluster

Redundant variables were filtered through use of a hierarchical cluster procedure, with the goal of grouping the 129 independent variables into different clusters, so as to identify redundant variables in the data sample using the Chebyshev and average methods for metrics and link criteria, respectively.

### F. Principal component analysis

In order to carry out the analysis of principal components with this methodology, a method based on correlation matrices is used. This is employed when the data are not dimensionally homogeneous, or the order of magnitude of each random variable measured is not equal. It begins with the correlation matrix, considering that the value of each of the  $X$  random variables  $F_j$  is present.

### G. Proposed hybrid algorithm

A general overview of the proposed hybrid methodology HC-SVM is presented in Fig.1.

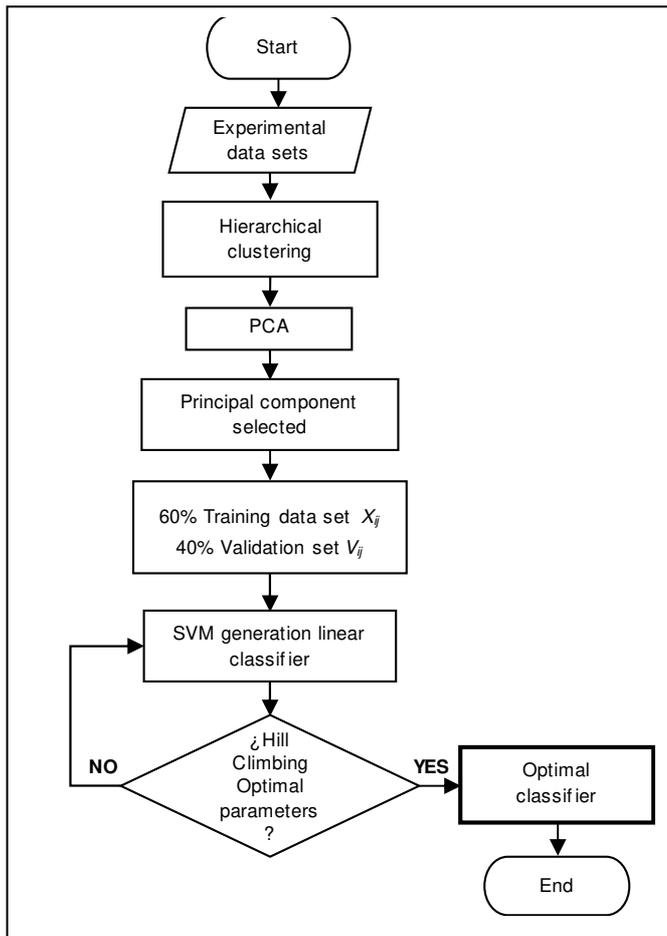


Fig. 1. General overview of the proposed hybrid model (HC-SVM)

## III EXPERIMENTS

### A. Datasets

There were 124 variables considered, with quantitative and qualitative values, and 5,340 sample registers which corresponded to the application of the psychosocial risk battery [17] on public school teachers in the metropolitan area of a Colombian city.

### B. Sample data with new physiological variables

The sample data analyzed comes from a database of the information collected from evaluations performed on 5,340 teachers, from which a random sample of 480 individuals, who participated voluntarily, was extracted. With this information, a database with 480 registers was created. New physiological variables ( $P_{ij}$ ) were added (Hearth rate ( $P_1$ ), electrodermal skin activity( $P_2$ ), and electromyography( $P_3$ )). This addition incorporated a total of 130 variables, 129 of which were independent, and one of which was dependent. This is the class composed of four values (Very high risk ( $Y_4$ ), high risk ( $Y_3$ ), medium risk ( $Y_2$ ), and low risk ( $Y_1$ )) as shown in Table 2.

TABLE II. INTRALABORAL PSYCHOSOCIAL RISK FACTOR DOMAIN VARIABLES AND PHYSIOLOGICAL VARIABLES. ADAPTED FROM: BATTERY FOR EVALUATION OF PSYCHOSOCIAL RISK FACTORS. [17] ANNEX 1.

People evaluated	Psychosocial risk Var					Pshysiological Var
	S Domain	D Domain	W Domain	L Domain	R Domain	
$X_1$	$X_1S_{1...}$ $X_1S_{10}$	$X_1D_{1...}$ $X_1D_{50}$	$X_1W_{1...}$ $X_1W_{21}$	$X_1L_{1...}$ $X_1L_{32}$	$X_1R_{1...}$ $X_1R_{11}$	$X_1P_{1...}$ $X_1P_3$
$X_2$	.	.	.	.	.	.
$X_{480}$	$X_{480}S_{1...}$ $X_{480}S_{10}$	$X_{480}D_1$ $X_{480}D_5$ $0$	$X_{480}W$ $1...X_{480}$ $0W_{21}$	$X_{480}L_1$ $...X_{480}$ $L_{32}$	$X_{480}R_1$ $...X_{480}$ $R_{11}$	$X_{480}P_{1...}$ $X_{480}P_3$

### C. Hierarchical cluster

The goal, when using the hierarchical cluster procedure, is to group the 129 independent variables into different clusters. A representative variable was chosen for each cluster, for a total of 30 representative variables to represent the group of 129.

Thus, variables belonging to each cluster were identified and grouped into each one of the variable group positions, which correspond to clusters. Next, the representative variable of each cluster was chosen. If, in a cluster, there was more than one variable, only one of them needed be selected. In order to make this selection, the distance between pairs of variables in said clusters were measured a new, and the variable with the lowest sum of distances between other variables was chosen, for a total selection of 30 variables from the entire group, as shown in Table 3.

TABLE III. VARIABLES SELECTED USING HIERARCHICAL CLUSTER.

Variables					
$S_2$	$S_6$	$S_7$	$S_9$	$S_{10}$	$S_{12}$
$D_{12}$	$D_{26}$	$D_{30}$	$D_{57}$	$D_{58}$	$D_{60}$
$D_{61}$	$D_{62}$	$W_{63}$	$W_{75}$	$W_{76}$	$W_{89}$
$W_{93}$	$W_{94}$	$W_{95}$	$W_{96}$	$W_{100}$	$L_1$
$L_2$	$L_3$	$R_1$	$P_1$	$P_2$	$P_3$

D. Principal component analysis

The analysis of principal components is a technique employed to reduce dimensionality in a group of data. In this case, each of the 480 individuals was initially represented by 129 points. With the redundant variable filter, each individual was represented by 30 points, using PCA, each person may be represented by up to two variables, thus facilitating their graphic representation. In accordance with the information obtained, the first component explains 99.21% of information variability, and the second 0.41%. With these two components, 99.62% of all variability may be explained. The third component, which corresponds to 0.14% may also be used, but the first two were deemed sufficient, see Fig. 2.

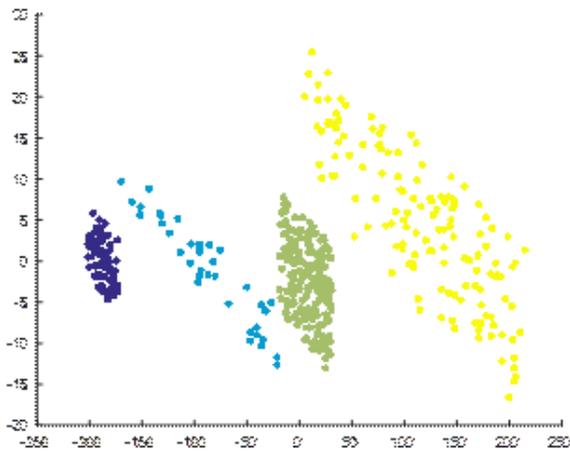


Fig. 2. Principal Component analysis

In the above diagram, each point corresponds to one of the 480 individuals, and each color represents a dependent variable value (risk). Note that separate groups were generated for each risk value.

E. Hybrid algorithm proposed

In support vector machines, finding a separating hyperplane

for two groups of data is an optimization problem. The diagram above shows that all of the groups are linearly separable from each other.

The equation for the sought-after separating hyperplane has the following form:

$$w^T x = 0 \tag{1}$$

Where vector  $w$  is a vector that contains hyperplane parameters, and  $x$  is a vector which contains the two selected characteristics, after having chosen the principal components.

$$w = w_0, w_1, w_3; x = I, x_1 \text{ and } x_2 \tag{2}$$

Where  $w_0, w_1$  y  $w_2$  are the hyperplane components, and  $x_1$  and  $x_2$  are the first and second components, respectively.

If the second component is cleared, the equation below is obtained:

$$x_2 = mx_1 + b \tag{3}$$

This is an equation for a straight line. In other words, the separating hyperplanes will be straight lines. In order to apply the hill climbing to this optimization problem, one must consider the minimization of vector  $w$ , which is a normal vector for the separator hyperplane.

Initially, there is separation of just one group from the other three, and later, there is separation of the other groups from each other. In order to separate group one from the others, it is only necessary to separate group one from group two. As such, only these two will be employed. Each pair  $(x_1, x_2)$  associated with the independent variable with a class or risk equal to one will be labeled with a value of one, while other pairs associated with a class or risk equal to two will be labeled with a value of -1.

F. Generation of a random individual

The first step in random reset hill climbing is the generation of a random solution, which is called an individual. In order to control the quality of each individual generated, the error variable is used.

These values are random, as it is unknown whether they truly complete the required function—it is merely a starting point. The error is calculated as the number of wrongly classified data, using vector  $w$ . In order for a data to be correctly classified, it must comply with the following condition:

Datum  $i$ , from the previously defined  $X$  group,  $X_{(i)}=[1 \ x_{1(i)} \ x_{2(i)}]$  and its label  $Y_{(i)} = y_i$ , where  $x_{1(i)}$  and  $x_{2(i)}$  are the first and second components of datum  $i$  respectively, and  $y_i$  is its label. It is correctly labeled if:

$$Y_{(i)}[w^T X_{(i)}] - 1 \geq 0 \tag{4}$$

Recall that  $X$  and  $Y$  are vectors within a matrix, and so, firstly, one of their vectors must be accessed to find the information. However, this step is omitted here for ease of reading.

### G. Cycle of number of iterations

Initially, only the algorithm for hill climbing is explained. The local search is performed with a number of  $k$ -local iterations. This value begins at one, and continues to 10,000, by experience.

### H. Generation of a new individual and its new associated error

The following corresponds to the creation of a new individual and calculation of its associated error. As mentioned previously, when using the hill climbing algorithm, after generation of the initial random solution, an attempt is made to find a better solution, through variation of a single element of the solution. In this case, the new individual is generated by making a random change in the present individual, and the new individual's error is calculated with the wrongly classified function, as explained above.

Initially, a new individual is created, which is equal to the previous one. This is done in order to make changes to a new variable in the individual, without losing its information.

### I. Comparison of error1 and error2

Following implementation of the hill climbing algorithm, if, after making the change, a better solution is produced, another change is made to the new solution. This process is repeated until improvements can no longer be made. The production of a better solution is confirmed through error: a better solution has a lower error than its individual predecessor.

### J. Implementation

Application of the new algorithm to the group of experimental data from the sample group of public school teachers, see Table 4.

TABLE IV. RESULTS FROM HC-SVM CLASSIFICATION ALGORITHM.

% Training	% Validation	HC- SVM/Err	SVM/Err	ANN/Err
20	80	0.90/0.01	0.89/0.11	0.87/0.13
50	50	0.92/0.08	0.91/0.09	0.89/0.11
80	20	0.95/0.05	0.92/0.08	0.90/0.10

The results show that, in this case, the algorithm improves the classification percentages and rate of error as it improves the model training data.

### K. Evaluation of the data group

There were 100 replications performed with each algorithm, and the best 5 were selected to be exhibited. The obtained results are shown in Table 5.

TABLE V. REPLICATIONS WITH EACH ALGORITHM AND THEIR GENERAL AVERAGE.

Algrthms	Replications					Simple Average
HC-SVM/ Error	0.949/ 0.051	0.948/ 0.052	0.948/ 0.052	0.949/ 0.051	0.948/ 0.052	0.9484/ 0.0516
SVM RBF/Error	0.892/ 0.108	0.893/ 0.107	0.892/ 0.108	0.893/ 0.107	0.893/ 0.107	0.8926/ 0.1074
ANN/ Error	0.903/ 0.097	0.903/ 0.097	0.903/ 0.097	0.901/ 0.099	0.901/ 0.099	0.9022/ 0.0978

## IV DISCUSSION

In [4] that investigation attempts to examine the feasibility of SVMs in predicting employee turnover. Besides, two other tradition regression models, Logistic and Probability models are used to compare the prediction accuracy with the SVM model. Subsequently, a numerical example of employee voluntary turnover data from a middle motor marketing enterprise in central Taiwan is used to compare the performance of three models. Empirical results reveal that the SVM model outperforms the logit and probit models in predicting the employee turnover based on job performance. Consequently, the SVM model is a promising alternative for predicting employee turnover in human resource management.

In [5] the project developed a Support Vector Machine for predicting nurses' intention to quit, using working motivation, job satisfaction, and stress levels as predictors. This study was conducted in three hospitals located in southern Taiwan. The target population was all nurses (389 valid cases). For cross-validation, we randomly split cases into four groups of approximately equal sizes, and performed four training runs. After the training, the average percentage of misclassification on the training data was 0.86, while that on the testing data was 10.8, resulting in predictions with 89.2% accuracy. This Support Vector Machine can predict nurses' intention to quit, without asking these nurses whether they have an intention to quit.

In Colombia, attempts are currently being made to design and implement an AI algorithm, based on a group of data from evaluations which were previously administered specifically in a population from the educational sector schools [18]. Previous studies compare the classification effectiveness of models such as artificial neural network algorithms, decision trees, and Naive Bayes, and uses genetic algorithms to reduce dimensionality and to improve precision levels, with values of

93% [19] and in [20] compare Support Vector Machines, Naïve Bayes Classifier and Genetic Algorithms for predicting psychosocial risk levels in Colombian teachers school.

In this research, a new approach will adopted, based on the support vector machine algorithm and hill climbing, called HC-SVM, in order to predict psychosocial risk levels in public school teachers in the metropolitan area of a Colombian city.

This hybrid is promising for psychosocial risk analysis in Colombian public school teachers. It is also necessary to implement processes which allow for collection of data groups by geographical region, given that environmental, cultural, and social conditions affect classification results.

#### V CONCLUSION

In this investigation, the principal objective was to develop a new hybrid classification method which would allow for evaluation and prediction of psychosocial risk levels, through consideration of existing epidemiological data, thus reducing the dimensionality of existing instruments and improving the degree of prediction precision through reduction of redundant variables and increase the accuracy.

Its second contribution was the application of an optimization method which allowed for discovery of the optimal values within the support vector function, so as to classify all existing data in the search space and achieve very high classification values. This space was composed of values, and the algorithm modified itself constantly in order to reduce the risk of false alarms and new missed classes.

The process for evaluation of controlled characteristics proposed a multiple support vector machine with random restart hill climbing optimization, called HC-SVM. The empirical evaluation of the modified algorithm is better than that of the SVM algorithm.

The error rate of the modified algorithm decreases and the precision rate increases, in contrast to the SVM algorithm.

For future investigations, in the field of artificial intelligence, identification of psychosocial risk associated with facial recognition, supported by registered data, is necessary, as is the development of new algorithms which would allow for the association of physiological variables with specific psychosocial aspects for the prevention of occupational illnesses. The development of algorithms which identify musculoskeletal problems associated with psychosocial risks for illness prevention are similarly urgent, as well as the development of algorithms which classify lean manufacturing variables with psychosocial risks, so as to predict the development of occupational illnesses.

#### REFERENCES

[1] International Labour Office, & Labour Administration, L. I. and O. S. and H. B. Workplace stress: a collective challenge. Geneva: ILO, 2016.  
 [2] Kortum, E., Leka, S., & Cox, T. Psychosocial risks and work-related stress in developing countries: health impact, priorities, barriers and solutions. *International Journal of Occupational Medicine and*

*Environmental Health*, 23(3), 2010. <https://doi.org/10.2478/v10001-010-0024-5>  
 [3] Ministerio del Trabajo, & Organización Iberoamericana de Seguridad Social-OISS. II encuesta nacional de condiciones de seguridad y salud en el trabajo en el sistema general de riesgos laborales. 2da ed., Vol. 1. Bogotá, 2015.  
 [4] Hong, W.-C., Pai, P.-F., Huang, Y.-Y., & Yang, S.-L. Application of Support Vector Machines in Predicting Employee Turnover Based on Job Performance. En L. Wang, K. Chen, & Y. S. Ong (Eds.), *Advances in Natural Computation*, Vol. 3610, pp. 668–674, 2005. Berlin, Heidelberg: Springer Berlin Heidelberg. [https://doi.org/10.1007/11539087\\_85](https://doi.org/10.1007/11539087_85)  
 [5] Tzeng, H.-M., Hsieh, J.-G., & Lin, Y.-L. Predicting Nurses' Intention to Quit With a Support Vector Machine. *CIN: Computers, Informatics, Nursing*, 22(4), 232–242, 2004.  
 [6] Brown, M. P., Grundy, W. N., Lin, D., Cristianini, N., Sugnet, C. W., Furey, T. S., ... & Haussler, D. Knowledge-based analysis of microarray gene expression data by using support vector machines. *Proceedings of the National Academy of Sciences*, 97(1), 262–267, 2000.  
 [7] Molina, V., Vera, M., Robles, H. V., Bejarano, E., & Dávila, H. Lung segmentation using Support Vector Machine in computed tomography images. In *Health Care Exchanges (PAHCE)*, 2014 Pan American (pp. 1-5). IEEE. April 2014.  
 [8] Salahshoor, K., Kordestani, M., & Khoshro, M. S. Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy inference system) classifiers. *Energy*, 35(12), 5472–5482, 2010.  
 [9] Mahadevan, S., & Shah, S. L. Fault detection and diagnosis in process data using one-class support vector machines. *Journal of process control*, 19(10), 1627–1639, 2009.  
 [10] Sapankevych, N. I., & Sankar, R. Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2), 2009.  
 [11] Vapnik, V. *The Nature of Statistical Learning Theory*. Ed: Springer-Verlag, New York, 1995.  
 [12] Cortes, C., Vapnik, V. Support-vector network, *Mach. Learn.* 20, pp 273–297, 1995.  
 [13] Vapnik, V. *The Nature of Statistical Learning*, second ed., Springer, New York, 1998.  
 [14] Cristianini, N.J., Shawe-Taylor. *An Introduction to Support Vector Machines*, Cambridge University Press, 2000.  
 [15] Kotsiantis, S.B., Zaharakis, I.D., Pintelas, P.E., *Machine learning: a review of classification and combining techniques*. *Artif. Intell. Rev.* 26, 159–190, 2006.  
 [16] Jacobson, S. H., & Yücesan, E. Analyzing the performance of generalized hill climbing algorithms. *Journal of Heuristics*, 10(4), 387–405, 2004..  
 [17] Villalobos, G.; Vargas, A. M.; Escobar, J.; Jiménez, M. L. y Rondón, M. A. *Batería de instrumentos para la evaluación de factores de riesgo psicosocial*. Bogotá: Ministerio de la Protección Social, 2010.  
 [18] Mosquera, Rodolfo, Parra-Osorio, L., & Castrillón, O. D. Methodology for Predicting the Psychosocial Risk Level on Colombian Teachers using Data Mining Techniques. *Inf. Tecnol.* 27(6), 259–272. 2016. <https://doi.org/10.4067/S0718-07642016000600026>  
 [19] Mosquera, Rodolfo, Parra-Osorio, L., & Castrillón, O. D. Prediction of Psychosocial Risks in Colombian Teachers Public Schools Using Machine Learning Techniques. *Inf. Tecnol.* 29(4), 267–280, 2018. <http://dx.doi.org/10.4067/S0718-07642018000400267>  
 [20] Mosquera, Rodolfo, Parra-Osorio, L., & Castrillón, O. D. Support Vector Machines, Naïve Bayes Classifier and Genetic Algorithms for the Prediction of Psychosocial Risks in Teachers of Colombian Public Schools. *Inf. Tecnol.* 29(6), in press.



# Una aproximación desde la inteligencia computacional al tratamiento de datos de aseguradoras y accidentes

Ander Carreño

Start Date: 22 January 2018

Advisors: Iñaki Inza<sup>1</sup> and Jose A. Lozano<sup>1,2</sup>

<sup>1</sup> Intelligent Systems Group, Universidad del País Vasco UPV/EHU  
P. Manuel Lardizabal 1, 20018 San Sebastián (España)

<sup>2</sup> BCAM - Basque Center for Applied Mathematics  
Avda. Mazarredo 14, 48009 Bilbao (España)  
Emails: { ander.carreno, inaki.inza, ja.lozano }@ehu.eus

## I. RESUMEN

En los últimos años, dentro del aprendizaje automático, ha surgido un gran interés por lo peculiar, raro, novedoso, sorprendente, anómalo, eventual, curioso, anormal o atípico. Tanto es así que áreas como la medicina [1], la geología [2], la banca [3], la seguridad informática [4] o la seguridad ferroviaria [5] han hecho avances en la detección de situaciones anómalas que se desvían notablemente del comportamiento habitual. Estas situaciones tienen la particularidad de que ocurren pocas veces, o lo que es lo mismo, que ocurren con baja probabilidad. Por lo tanto, detectarlas mediante técnicas predictivas es una tarea difícil. Pese a ello, numerosos trabajos han sido propuestos. La causa principal de la proliferación de estos artículos es que estos eventos están habitualmente asociados con causas críticas, como lo son los accidentes de tráfico [6] o las erupciones volcánicas [2]. Además, la detección de estos eventos supone un reto científico de especial interés dado que es necesario proponer avances metodológicos para dar solución a estos problemas.

Recientemente, el aprendizaje automático se ha incorporado al desarrollo de modelos para la predicción de eventos raros. Sin embargo, en contadas ocasiones se utiliza la terminología evento raros [7]. Este término es más común en otras áreas como la estadística, la ingeniería o la física. A pesar de ello, existen otro tipo de aproximaciones que tangencialmente tratan este problema de predicción; aunque poseen diferentes nombres:

- Clasificación supervisada en conjuntos extremadamente desequilibrados [8]. Se plantea un problema de clasificación donde una de las clases tiene una probabilidad de ocurrencia a priori extremadamente pequeña. No obstante, las instancias anómalas forman una clase, por lo que estas instancias comparten características entre sí. Por lo tanto, técnicas de muestreo como SMOTE [9] son un buen punto de partida para este escenario.

- *One-class classification* [10], [11]. En este caso el objetivo es crear un clasificador donde únicamente se trata de identificar casos de una sola clase, la clase de interés, es decir el evento raro. Muchos de los trabajos que utilizan la técnica de clasificación *one-class* se refieren a las anomalías como novedades. Al aprender un modelo sobre únicamente instancias de la clase conocida, la que es proporcionada en el momento de entrenamiento, cuando una nueva instancia, se clasifica como novel es porque es discordante con respecto al conjunto proporcionado.
- Detección de eventos raros [5]. En este escenario de clasificación, muchos de los trabajos que se han propuesto tienen la dimensión temporal como un elemento fundamental.
- Detección de outliers [12]. Al igual que en el caso anterior el objetivo es detectar datos en un conjunto que escapan a la situación más común. Sin embargo, muchos de los trabajos que describen las anomalías con el término outlier, toman una aproximación no supervisada.

Pese a que el problema de detección de eventos raros ha sido tratado en los últimos años, no se han realizado avances en la regresión sobre las características asociadas a un evento raro. Por ejemplo, es de gran interés predecir la escala Richter de un terremoto antes de que suceda. Dado que se podrían tomar medidas de evacuación y seguridad. Para llevar a cabo este análisis, no sólo es necesario detectar el terremoto, sino que también es necesario estimar la escala de éste. Otro ejemplo es la predicción del gasto por indemnizaciones asociado a un accidente de tráfico. Donde el problema deja de ser un problema de clasificación para convertirse en un problema de regresión.

Por lo tanto, este proyecto de tesis trata de aportar contribuciones metodológicas al ámbito de la regresión en eventos raros y su aplicación sobre datos reales de compañías de seguros. Para ello, se establecen los siguientes objetivos que

se alcanzarán durante el transcurso de la tesis doctoral:

- **Objetivo I.** Organizar el conocimiento dentro del ámbito del aprendizaje automático sobre la detección de eventos raros.
- **Objetivo II.** Desarrollar técnicas de regresión en el ámbito de eventos raros a partir de la detección inicial del evento raro mediante técnicas de clasificación.
- **Objetivo III.** Desarrollar técnicas de regresión en eventos raros de forma directa, es decir, sin predecir con anterioridad la existencia del evento raro mediante técnicas de clasificación.
- **Objetivo IV.** Aplicar las técnicas desarrolladas en los objetivos anteriores sobre datos reales provenientes de una compañía de seguros pública en la predicción de indemnizaciones.

Para la consecución de estos objetivos, la metodología a seguir contempla que una vez acabado uno de los objetivos, este será formalizado en un documento científico que será enviado para revisión y evaluación a una revista del ISI, pudiendo enviar algunos resultados parciales a congresos de prestigio dentro del área. En concreto, esta metodología desencadena las siguientes **tareas** para cada uno de los objetivos, siendo:

- **Objetivo I.** Organizar el conocimiento dentro del ámbito del aprendizaje automático sobre la detección de eventos raros.
  - Tarea 1.1. Búsqueda de bibliografía dentro del ámbito del aprendizaje automático que este relacionada con la detección de eventos raros. Además de buscar información relativa a los términos mencionados en el apartado de “antecedentes”, se tratará de buscar también la existencia de otros trabajos que con términos diferentes hayan abordado el problema de la detección de eventos raros.
  - Tarea 1.2. Organización de la información obtenida. Se identificarán aquellas características que agrupen tanto a problemas como algoritmos.
  - Tarea 1.3. Se redactará un artículo de investigación de revisión con la estructuración de la información anterior. Dicho artículo tendrá como uno de sus objetivos establecer una terminología común.
- **Objetivo II.** Implementar técnicas originales y novedosas de regresión en el ámbito de eventos raros a partir de la detección inicial del evento raro mediante técnicas de clasificación.
  - Tarea 2.1. Implementación de varias técnicas de clasificación supervisada para la detección de eventos. Partiendo de la revisión llevada a cabo en el anterior objetivo, se implementarán aquellas técnicas que parezcan más adecuadas para el posterior trabajo de regresión.
  - Tarea 2.2. Implementación de varias técnicas de regresión que tengan en cuenta que los posibles valores de salida de la regresión asociados al evento raro pueden tener gran variabilidad. La elección de las técnicas se llevará cabo tras un estudio bibliográfico

exhaustivo.

- Tarea 2.3. Creación de varios modelos de predicción híbridos basados en la detección del evento raro mediante técnicas de clasificación para a posteriori realizar la regresión asociada a dicho evento. Uniendo técnicas clásicas de estadística con algoritmos de aprendizaje automático.
- Tarea 2.4. Preparación de un documento científico con lo realizado para la consecución del objetivo.
- **Objetivo III.** Implementar técnicas novedosas de regresión en eventos raros de forma directa, es decir, sin predecir con anterioridad la existencia del evento raro mediante técnicas de clasificación.
  - Tarea 3.1. Estudiar en la literatura técnicas de regresión que consideren la existencia de eventos raros.
  - Tarea 3.2. Desarrollar técnicas capaces de predecir el valor de interés asociado a un evento raro. En el desarrollo de estas técnicas se considerará de especial manera la hibridación entre técnicas estadísticas clásicas con métodos de aprendizaje automático.
  - Tarea 3.3. Implementación y evaluación de las diferentes técnicas desarrolladas. Se creará un software que se pondrá a disposición de la comunidad científica. Este software, que recogerá las técnicas desarrolladas, se implementará en el lenguaje R y se subirá al repositorio CRAN. Dependiendo del número y novedad de las técnicas desarrolladas se escribirá un artículo donde se detallarán las características del paquete desarrollado, el cual será enviado a revistas como *The R journal* o *Journal of Statistical Software*.
  - Tarea 3.4. Preparación de un documento científico con lo realizado para la consecución del objetivo. Este trabajo, además de incluir los avances metodológicos, contendrá una experimentación detallada donde se utilizarán los datos de una compañía de seguros. En concreto, se hará regresión sobre las características asociadas a un accidente. Este documento contendrá todos los avances de la investigación y será publicado en una revista de alto impacto en la comunidad.
- **Objetivo IV.** Aplicar las técnicas desarrolladas en los objetivos anteriores sobre datos reales provenientes de una compañía de seguros pública en la predicción de indemnizaciones.
  - Tarea 4.1. Preproceso de los datos. El objetivo de esta tarea es realizar el preproceso de los datos que recibiremos de la compañía de seguros. Particularmente, se tratarán los datos perdidos, los registros incoherentes, y se llevará a cabo una selección de características.
  - Tarea 4.2. Aplicación de los métodos desarrollados en los objetivos anteriores a la predicción de las indemnizaciones. Este proceso será un proceso iterativo y se contará con apoyo de la compañía de



seguros aportando “feedback” sobre los resultados obtenidos.

- Tarea 4.3. Preparación de un documento científico con lo realizado para la consecución del objetivo. En este documento se incorporará una experimentación detallada donde se hará regresión sobre las características asociadas a un accidente de trabajo. Además, se compararán los resultados tanto con los de los trabajos anteriormente presentados como con las contribuciones relevantes en el área. Por último, los resultados parciales de este trabajo serán enviados a un congreso internacional de prestigio, como por ejemplo a *Conference on Artificial Intelligence (AAAI)* o a *Conference on Neural Information Processing Systems (NIPS)*.

## II. ESTADO DEL ARTE

La detección de eventos raros se caracteriza por la baja probabilidad con la que suceden este tipo de eventos. De forma similar, los problemas de clasificación con distribuciones de probabilidad desbalanceadas están relacionados con la detección de eventos raros. No obstante, en la literatura proliferan una serie de términos que están relacionados entre sí pero que tienen diferencias clave. En algunas situaciones, las anomalías son descritas como eventos raros, anomalías, novedades, outliers, excepciones, aberraciones, sorpresas, peculiaridades, ruido o contaminantes entre otras. De todas estas acepciones, las más comunes son: eventos raros, anomalías, novedades y outliers.

La importancia de detectar estas anomalías es debido a que estas pueden estar relacionadas con situaciones críticas o interesantes en una gran cantidad de dominios. Por ejemplo, en seguridad, las intrusiones son consideradas anomalías [4], [5], [13]; en seguridad vial, los accidentes de tráfico son considerados anomalías [6]; en geología, la erupción de un volcán [2]; en el control de alimentos, cuerpos extraños dentro de envoltorios son también anomalías [14]; o en el caso de la neurociencia, un estímulo que no se ha experimentado anteriormente es también una anomalía [1].

Considerando la importancia de las anomalías, se ha desarrollado una larga lista de trabajos relacionados con estos términos. Sin embargo, se ha formado una mezcla entre los términos y los problemas. En primer lugar, se han utilizado diferentes términos para describir el mismo problema. Por ejemplo, en [15], los autores tratan un problema en el que predicen si se va a producir un desprendimiento en una zona concreta y en un periodo de tiempo acotado. Para ello, crean un mapa de zonas susceptibles a que ocurra un desprendimiento. Cada zona tiene asociado un riesgo de desprendimiento. Este riesgo se predice con un modelo aprendido con datos sobre zonas donde ha ocurrido un desprendimiento y zonas en las que no. Es decir, el modelo se aprende con datos etiquetados en dos categorías: desprendimiento y no desprendimiento. Estos desprendimientos de tierra son descritos como *eventos raros*, denotando que son eventos que ocurren pocas veces. No obstante, en [5], se trata un problema similar desde el

punto de vista de la clasificación supervisada, pero que se describe con otro término. En éste, se realiza un estudio en la industria ferroviaria. Las puertas de pasajeros cuentan con diferentes sistemas para abrir y cerrar las puertas de los trenes, que aseguran el confort y la seguridad de los pasajeros abordo. En algunas situaciones, por el deterioro de estos sistemas, el sistema de apertura y cierre de las puertas falla. Por lo tanto, la tarea de análisis se enfoca en predecir si la puerta va a fallar en un periodo de tiempo acotado. Para ello, se aprende un modelo con datos etiquetados en dos categorías: fallos (puertas que fallan) y situaciones normales. En este estudio, los errores en las puertas se denominan *anomalías*, denotando también situaciones que ocurren pocas veces. Como se puede ver, los dos problemas son prácticamente idénticos desde el punto de vista de la clasificación supervisada, pero se han utilizado diferentes términos para describir las anomalías. Por lo tanto, analizando los problemas desde el punto de vista de la clasificación supervisada, ambos problemas se pueden modelar como problemas de clasificación binarios con distribuciones de probabilidad desbalanceadas en las clases.

Por otro lado, también el mismo término ha sido utilizado para describir problemas diferentes. En los siguientes dos escenarios de aprendizaje, los autores utilizan el término *novedad*, *novelty* en inglés, para describir las anomalías. En [13], los autores predicen si un paciente está sufriendo un ataque epiléptico. Dada la fuerza de las convulsiones que sufren estos pacientes durante un ataque, pueden hacerse daño a ellos mismos. En consecuencia, detectar estos ataques lo más rápido posible es muy importante para evitar los daños. Por lo tanto, el objetivo de este estudio es detectar si un paciente está sufriendo un ataque epiléptico. Para ello, se aprende un modelo predictivo con datos de movimientos de pacientes recogidos con un acelerómetro 3D. Estos datos previamente han sido grabados durante varios días en los cuales, en algún momento, los pacientes han sufrido una o varias convulsiones. Después, estos datos son segmentados en ventanas de tiempo fijas y, estas particiones son etiquetadas como ataque o normal por el experto. Por lo tanto, cuando llega un nuevo caso, es decir, al recibir los datos de un paciente que está constantemente monitorizado, el clasificador detecta si está o no sufriendo un ataque epiléptico (i.e. identificado como novedad). Sin embargo en [14], se detectan cuerpos extraños dentro de contenedores de alimentos. En algunas ocasiones, ciertos cuerpos extraños como insectos, piedras o plásticos son encontrados dentro de los envoltorios de alimentos, tales como bandejas o tetrabriks. Detectar estos cuerpos extraños es muy importante para la imagen de las empresas productoras de este tipo de productos y para los consumidores finales. Por lo tanto, partiendo únicamente de imágenes de rayos X de alimentos limpios de cuerpos extraños, desde nuestro prisma, de una única clase, se aprende un modelo que es capaz de detectar estos cuerpos extraños, que son descritos como novedades en este estudio. Como se puede apreciar en ambos ejemplos, el mismo término (novedad) ha sido utilizado para describir las anomalías. No obstante, ambos trabajos no se basan en el mismo escenario de aprendizaje, y en [13] el modelo

predictivo es aprendido con tanto instancias normales como anormales mientras que en [14] únicamente se aprende el modelo con datos normales (sin cuerpos extraños).

Sin embargo, no sólo los problemas descritos anteriormente, sino la mayoría de los problemas reseñados con los términos eventos raros, anomalías y novedades, se pueden formalizar como problemas de clasificación supervisada.

### III. RELEVANCIA

Como se puede ver, en los últimos años ha habido una proliferación de trabajos en los que se detecta lo atípico o anormal. Sin embargo, al revisar la mayoría de estos trabajos, se puede ver que distan unos de otros teniendo en cuenta el objetivo del problema, la influencia de la dimensión temporal, las características de los datos, el entorno estático o dinámico, y la cantidad de clases en momento de entrenamiento. Por lo tanto, una taxonomía de este tipo de problemas es una contribución relevante en el área para organizar el conocimiento, no sólo en el área del aprendizaje automático sino en muchas otras con una rica trayectoria en aplicaciones de análisis de datos, como la medicina, las telecomunicaciones o la geología.

Por otro lado, la regresión de las características asociadas a una anomalía es muy relevante. Como se ha comentado, existen numerosos problemas reales en los cuales obtener un valor continuo asociado a una anomalía es de gran interés.

Por último, contribuir con un paquete que recogerá todas las técnicas y avances metodológicos para la regresión de anomalías es un avance y servicio para la comunidad. Además, dado que este paquete estará disponible en el lenguaje de programación R, será de software libre.

### REFERENCIAS

- [1] A. Kafkas and D. Montaldi, "How do memory systems detect and respond to novelty?" *Neuroscience Letters*, 2 2018.
- [2] Y. Dzierma and H. Wehrmann, "Eruption time series statistically examined: Probabilities of future eruptions at Villarrica and Llaima Volcanoes, Southern Volcanic Zone, Chile," *Journal of Volcanology and Geothermal Research*, vol. 193, no. 1-2, pp. 82–92, 2010.
- [3] C. Phua, V. Lee, K. Smith, and R. Gayler, "A Comprehensive Survey of Data Mining-based Fraud Detection Research," *Monash University*, 2010.
- [4] M. A. F. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko, "A review of novelty detection," *Signal Processing*, vol. 99, pp. 215–249, 2014.
- [5] R. P. Ribeiro, P. Pereira, and J. Gama, "Sequential anomalies: a study in the Railway Industry," *Machine Learning*, vol. 105, no. 1, pp. 127–153, 10 2016.
- [6] A. Theofilatos, G. Yannis, P. Kopelias, and F. Papadimitriou, "Predicting Road Accidents: A Rare-events Modeling Approach," *Transportation Research Procedia*, vol. 14, pp. 3399–3405, 2016.
- [7] J. F. Murray, G. F. Hughes, and K. Kreutz-Delgado, "Machine Learning Methods for Predicting Failures in Hard Drives: A Multiple-Instance Application," *Journal of Machine Learning Research*, vol. 6, pp. 783–816, 2005.
- [8] N. V. Chawla, N. Japkowicz, and A. Ko, "Editorial: Special Issue on Learning from Imbalanced Data Sets," *Sigkdd Explorations*, vol. 6, no. 1, p. 1, 2004.
- [9] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002. [Online]. Available: <https://www.jair.org/media/953/live-953-2037-jair.pdf>
- [10] S. M. Erfani, S. Rajasegarar, S. Karunasekera, and C. Leckie, "High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning," *Pattern Recognition*, vol. 58, pp. 121–134, 2016.
- [11] F. Dufrenois and J. C. Noyer, "One class proximal support vector machines," *Pattern Recognition*, vol. 52, pp. 96–112, 2016. [Online]. Available: <http://dx.doi.org/10.1016/j.patcog.2015.09.036>
- [12] M. Radovanović, A. Nanopoulos, and M. Ivanović, "Reverse nearest neighbors in unsupervised distance-based outlier detection," *IEEE Transactions on Knowledge and Data Engineering*, 2015.
- [13] S. Luca, D. A. Clifton, and B. Vanrumste, "One-class classification of point patterns of extremes," *Journal of Machine Learning Research*, vol. 17, pp. 1–21, 2016.
- [14] H. Einarsdóttir, M. J. Emerson, L. H. Clemmensen, K. Scherer, K. Willer, M. Bech, R. Larsen, B. K. Ersbøll, and F. Pfeiffer, "Novelty detection of foreign objects in food using multi-modal X-ray imaging," *Food Control*, vol. 67, pp. 39–47, 9 2016.
- [15] M. Van Den Eeckhaut, T. Vanwalleghem, J. Poesen, G. Govers, G. Verstraeten, and L. Vandekerckhove, "Prediction of landslide susceptibility using rare events logistic regression: A case-study in the Flemish Ardennes (Belgium)," *Geomorphology*, 2006.



# Big Data Optimization: Framework Algorítmico para el análisis de Datos guiado por Semántica

Cristóbal Barba González

*Director: José Francisco Aldana Montes*

*Director: José Manuel Gracia Nieto*

*Grupo de investigación Khaos*

*Edificio de investigación Ada Byron*

*Departamento de Lenguajes y Ciencias de la Computación*

Universidad de Málaga, España.

cbarba@lcc.uma.es

Inicio: Marzo 2015

**Resumen**—En las últimas décadas el aumento de fuentes de información en diferentes campos de la sociedad desde la salud hasta las redes sociales, ha puesto de manifiesto la necesidad de nuevas técnicas para su análisis, lo que se ha venido a llamar el *Big Data*. Los problemas clásicos de optimización no son ajenos a este cambio de paradigma, como por ejemplo el problema del viajante de comercio (TSP), ya que se puede beneficiar de los datos que proporciona los diferentes sensores que se encuentran en las ciudades y que podemos acceder a ellos gracias a los portales de *Open Data*. En esta tesis se ha desarrollado un nuevo framework, *jMetalSP*, para la optimización de problemas en el ámbito del *Big Data* permitiendo el uso de fuentes de datos externas para modificar los datos del problema en tiempo real. Por otro lado, cuando estamos realizando análisis, ya sea de optimización o machine learning en *Big Data*, una de las formas más usada de abordarlo es mediante workflows de análisis. Estos están formados por componentes que hacen cada paso del análisis. El flujo de información en workflows puede ser anotada y almacenada usando herramientas de la Web Semántica para facilitar la reutilización de dichos componentes o incluso el workflow completo en futuros análisis, facilitando así, su reutilización y a su vez, mejorando el procesos de creación de los mismos. Para ello se ha creado la ontología *BIGOWL*, que permite trazar la cadena de valor de los datos de los workflows mediante semántica y además ayuda al analista en la creación de workflow gracias a que va guiando su composición con la información que contiene por la anotación de algoritmos, datos, componentes y workflows.

**Index Terms**—*Big Data, Optimización, Machine Learning, Web Semantic*

## I. INTRODUCCIÓN

Debido al gran avance que existe día a día en las tecnologías de información, las organizaciones se han tenido que enfrentar a nuevos desafíos que les permitan analizar, descubrir y entender más allá de lo que sus herramientas tradicionales reportan sobre su información. Existen numerosas fuentes de información como son, las aplicaciones disponibles en internet (redes sociales, geo-referenciamiento, etc.); la información obtenida en el campo de la medicina y biología con la secuenciación del ADN y otros datos analíticos, etc. Todos estos datos se conocen como *Big Data* y hace necesario el uso de nuevos enfoques para el análisis de los mismos,

debido principalmente, a que las técnicas tradicionales usadas hasta ahora (Machine Learning y Optimización) no están diseñadas ni optimizadas para manejar grandes volúmenes de información [1].

El término *Big Data* por tanto, hace referencia a aquellos datos que no pueden ser procesados o analizados usando las técnicas tradicionales [2]. El análisis del *Big Data* permite extraer información a partir de estos datos. Multitud de soluciones software alrededor del proyecto Apache Hadoop van resolviendo las diferentes problemáticas a través de este proyecto y otros complementarios. Alguno de estos proyectos son:

- *Apache Hadoop*. Que integra el framework MapReduce y el sistema de archivos HDFS.
- *Apache Spark*. Framework que permite realizar tareas de transformación y de acción sobre los datos en streaming de manera eficiente.

De acuerdo con Gartner<sup>1</sup> y la asociación europea *Big Data Value (BDVA)*<sup>2</sup>, hay un reto en el campo del *Big Data* acerca de la construcción de aplicaciones que inyecte el conocimiento del dominio (problema, algoritmo, dato, etc.), así como el contexto, en el proceso de análisis. Por contexto entendemos toda la (meta)información relevante que permita interpretar los resultados del análisis. Esto tendrá como consecuencia la accionabilidad de dichos resultados. Así facilitará la interpretación de estos datos; permitirá integrarlos fácilmente con otros datos estructurados; facilitará la integración del sistema de análisis del *Big Data* con otros sistemas y habilitará la interconexión de algoritmos. En esta tesis hemos abordado este reto creando *BIGOWL*, una ontología en la que se ha definido toda la semántica necesaria para poder definir cualquier problema de análisis en el ámbito del *Big Data* así como los algoritmos y datos a utilizar para dicho análisis.

Uno de los principales problemas que nos encontramos a la hora de trabajar con *Big Data* es la eficiencia de los algoritmos

<sup>1</sup><https://www.gartner.com/doc/3656517/adopt-datadriven-approach-consolidating-infrastructure>

<sup>2</sup><http://www.bdva.eu/>

de optimización a la hora de procesar grandes volúmenes de información, sobre todo en tiempo de cómputo, por ello es necesario realizar algoritmos optimizados para problemas de Big Data. Existen dos grandes tipos de problemas de optimización los llamados mono-objetivo y los multi-objetivo. Este trabajo se ha centrado en los problemas multi-objetivo ya que existen muchos en Big Data. Para ello hemos desarrollado *jMetalSP* que es una librería de algoritmos de optimización adaptados para Big Data, el cual está basado en *jMetal* [3], una herramienta para la optimización multi-objetivo y Apache Spark [4]. Dentro de los algoritmos multi-objetivo desarrollados en *jMetalSP*, nos hemos centrado en los algoritmos dinámicos y en los interactivos, ya que facilitan reducir el espacio de búsqueda de soluciones de un problema y por tanto, reducir el tiempo de cómputo quedándose sola con las áreas preferidas por el analista (Decision Maker). Además permiten abordar procesamiento en streaming (Velocidad), actuar ante cambios en el problema, datos o entorno (Variabilidad) y acercar el proceso de optimización al Decision Maker (Valor, Veracidad).

## II. ANTECEDENTE E HIPÓTESIS DE PARTIDA

Los problemas de procesamiento que dan lugar al Big Data provienen de la cantidad de datos, que es desproporcionadamente grande y del origen de la información, que es muy variado (fuentes, formato, etc.). Estos problemas asociados al Big Data se entienden en cinco dimensiones (las denominadas “cinco uves”): Volumen, Velocidad, Variedad, Variabilidad y Veracidad. El Big Data trae consigo la posibilidad de encontrar información relevante en los nuevos tipos de datos emergentes la capacidad de abordar cuestiones que hasta no hace mucho eran imposibles de plantear. El análisis del Big Data puede revelar información importante que anteriormente permanecía oculta debido al elevado coste de procesar ciertos datos, tales como las tendencias sociales de opinión, tendencias de consumo de ciertos productos comerciales, orientación y seguimiento publicitario, etc.

En general, la generación de un análisis en Big Data es compleja ya que entran en juego diferentes aplicaciones o algoritmos, concretamente diferentes componentes, que se tienen que interconectar entre ellos y tienen que ser compatibles, es decir, los datos de salida de uno son los de entrada del siguiente. En este sentido, esta tesis se propone que el uso de la semántica apoyado con tecnologías de la Web Semántica puede ayudar en la anotación de toda la información necesaria para que componentes distintos puedan interactuar entre ellos, facilitando así la interconexión entre componentes, su reutilización y la trazabilidad de la cadena de valor de los datos.

La problemática se encuentra en dar estructura a esta información para poder ser integrada en los componentes. De hecho, la automatización de este proceso es uno de los grandes retos en los que las tecnologías relacionadas con los estándares de la Web Semántica podrían tener un papel relevante.

Hoy en día se están desarrollando una serie de plataformas para el análisis del Big Data que además ofrecen una conexión con otros sistemas para la asistencia en la toma de decisiones.

No obstante, hasta donde llega nuestro conocimiento, estos frameworks no incluyen una anotación semántica de sus elementos (componentes, algoritmos, métodos, interfaces, etc.) que facilite la reutilización y la composición de workflows de análisis del Big Data. Tampoco aprovechan la semántica específica del dominio de aplicación de forma que se facilite el desarrollo de los workflows de análisis, la anotación de los datos y los metadatos y/o de los resultados de los algoritmos, además de la generación de nuevos operadores adaptados que utilizan la estructura semántica del dominio del problema. Esto provoca que:

1. Los algoritmos de análisis del Big Data no son fácilmente reutilizables, no son capaces de explotar la semántica y, por tanto, la creación de workflows “inteligentes” es complicado y requiere desarrollo ad hoc.
2. No existe un procedimiento estandarizado para conectar los resultados del análisis del Big Data con otros sistemas.

Todas estas razones nos llevan a plantear la principal hipótesis de este proyecto: la “*anotación semántica*” de los componentes software que constituyen un framework para el análisis del Big Data puede actuar como nexo de unión, tanto para la generación de nuevas propuestas algorítmicas que utilicen este conocimiento semántico, como para su final conexión con otros sistemas. Se reutiliza así la idea fundamental de la Web Semántica en el contexto del Big Data orientado a la optimización.

Por otro lado, hemos desarrollado un framework para el análisis del Big Data, centrándonos en la optimización multi-objetivo para Big Data, más concretamente en metaheurísticas dinámicas y/o interactivas. Este framework, junto con otros de Machine Learning (WEKA, Scikit Learn Python, MLlib Spark, etc.), se usarán como casos de uso para comprobar que la anotación de sus componentes es capaz de cubrir completamente sus especificaciones.

Los algoritmos que se han desarrollado en el framework se usarán en diferentes problemas reales, como son: la bioinformática o la búsqueda de la ruta óptima en tráfico. Hemos integrado el framework *jMetal*, como base, que proporciona una gran batería de algoritmos de optimización multi-objetivo, junto con el modelo de programación MapReduce [5] y el framework Spark [4].

Otro de nuestros objetivos es realizar un benchmark para los algoritmos interactivos que se desarrollen en esta tesis y que nos permita compararlos ya que solo existe uno en el estado de arte actual [6].

## III. OBJETIVOS

Esta tesis tiene como objetivo el integrar técnicas y resultados del análisis del Big Data con una capa de metadatos (de los datos objetos del análisis, de las técnicas de análisis y del dominio donde éstas se aplican) para romper las barreras de acceso y aplicabilidad relacionados con las tecnologías de análisis del Big Data. Como enfoque principal el desarrollo de herramientas para dicho análisis, nos centramos en la optimización en Big Data. Concretamente los principales objetivos son:



- O 1. Definir un modelo ontológico para la anotación semántica de algoritmos de análisis del Big Data.
  - O 1.1. Desarrollar una clasificación semántica de los algoritmos, componentes de procesamiento y visualización.
  - O 1.2. Diseñar una metodología para anotar la funcionalidad genérica de los algoritmos (tipo de algoritmos, entradas, salidas, transformación de los datos).
  - O 1.3. Diseñar una metodología para anotar las entradas, salidas y tipo de algoritmos según una ontología de dominio en caso de ser algoritmos específicos de un dominio de aplicación.
- O 2. Desarrollo de una plataforma para la optimización en problemas Big Data.
  - O 2.1. Estudio de nuevos algoritmos de análisis en Big Data (dinámicos y/o interactivos).
  - O 2.2. Desarrollo de mecanismos para la evaluación de algoritmos interactivos.
  - O 2.3. Diseñar la estructura del repositorio para incluir no sólo los algoritmos, sino también sus anotaciones semánticas relativas a su funcionalidad y los eventos que generan o consumen.
- O 3. Validación de la plataforma con casos de uso reales y académicos.
  - O 3.1. Problema del viajante de comercio en la ciudad de Nueva York con streaming Open Data.
  - O 3.2. Inferencia en Redes génicas (E.coli, Yeast).
  - O 3.3. Familia de problemas multi-objetivo DTLZ.
  - O 3.4. Familia de problemas dinámicos y multi-objetivo FDA.

#### IV. METODOLOGÍA Y PLAN DE TRABAJO

El método a utilizar es una adaptación del método Investigación en Acción de Avison, et al. [7]. Se trata de un método cualitativo utilizado para validar los trabajos de investigación mediante su aplicación a proyectos reales. En la Conferencia sobre Procesamiento de Información de 1998 se declaró a los métodos cualitativos como métodos de investigación apropiados para el campo de los sistemas de información [7], y los difundió en [8]. Proponemos un método de investigación genérico, basado en la propuesta de Bunge [9] y formado por etapas que, dada su generalidad, pueden aplicarse a cualquier tipo de investigación. Por tanto, utilizaremos un método de validación práctica, especialmente apropiado para la investigación en ingeniería y específicamente para validar aquellos resultados, en los que la aplicación de un método científico tradicional (inductivo o hipotético-deductivo) no son directamente aplicables. El método a seguir para la resolución y validación del problema concreto que nos ocupa (método de Investigación en Acción) no es un proceso lineal, sino que va avanzando mediante la compleción de ciclos. Al comenzar cada ciclo se ponen en marcha nuevas ideas, que son puestas en práctica y comprobadas hasta el inicio del siguiente ciclo [10]. Este proceso cíclico, en el que hemos ido probando y

refinando cada uno de los resultados obtenidos, será nuestro método de validación.

La metodología Software que se va a seguir estará inspirada en este método, ya que se tendrán como referencia modelos ágiles como Scrum <sup>3</sup>, basados en iteraciones de breve duración.

En concreto las tareas realizadas, para cada ciclo, son:

- **Observación.** Estudio pormenorizado del problema a tratar, realizando un estudio del estado del arte e identificando posibles riesgos antes de afrontar la tarea.
- **Formulación de hipótesis.** Declaración de la hipótesis que queremos llevar a cabo en dicho ciclo, se dividirá en pequeñas tareas abordables en la duración del ciclo.
- **Recogida de observaciones.** Obtención de resultados como consecuencia de la realización de las tareas del paso anterior.
- **Contrastes de hipótesis.** Estudio de las observaciones recogidas y comprobación si se han cumplido nuestras hipótesis de partida.
- **Demostración o refutación de hipótesis.** Aceptación o rechazo de la hipótesis, si es necesario una modificación de la misma, empieza un nuevo ciclo con estos cambios.

Para alcanzar los objetivos siguiendo esta metodología, se definieron los siguientes pasos del plan de trabajo:

1. Análisis de la tarea, estudiando el problema que queremos abordar, tecnología a usar y búsqueda de otras propuestas en el estado del arte.
2. Diseño de la tarea, estudio de detalles técnicos y patrones de diseño a usar, ya sea para aplicarlo a la implementación de nuevos algoritmos o la anotación de componentes de BIGOWL (ontología propuesta).
3. Implementación del diseño anteriormente indicado.
4. Validación de los resultados obtenidos mediante el uso de herramientas externas como pueden ser estadísticos, razonadores de ontología, etc.
5. Difusión y publicación de revistas y congresos internacionales de impacto o relevancia científica.

#### V. RELEVANCIA DE LA TESIS

Esta tesis está financiada mediante la beca *BES-2015-072209* del proyecto PERCEPTION [TIN 2014-58304-R] del Ministerio de Economía y Competitividad de España, además, se alinea directamente con las prioridades del PLAN ESTADAL DE INVESTIGACIÓN CIENTÍFICA Y TÉCNICA Y DE INNOVACIÓN 2013-2016 al plantear la generación de conocimiento en el ámbito de Big Data, y ser parte de la estrategia del grupo de investigación al que pertenezco, *grupo de investigación Khaos*<sup>4</sup> <sup>5</sup>. Por otro lado, la línea que se está siguiendo en dicha tesis, está en concordancia con las áreas prioritarias del Octavo Programa Marco de la Unión Europea Horizonte 2020, ICT-19- [2018-20]: Big Data PPP: *Methods and tools for extreme-scale analytics, and innovation hubs* en

<sup>3</sup><https://www.scrum.org>

<sup>4</sup><http://khaos.uma.es/>

<sup>5</sup><http://khaos.uma.es/cbarba>

el área de “investigación e innovación”, en la que se esperan proyectos para desarrollar entre otros, algoritmos, arquitecturas software y metodologías de optimización novedosas para el análisis del Big Data.

En la Figura 1. se pueden ver las principales líneas de investigación que se están siguiendo en esta tesis. Como elemento central tenemos la optimización en Big Data la cual se apoya en los otros conceptos, como por ejemplo, los modelos de la web semántica para la anotación de los componentes de los workflows con el fin de mejorar el proceso de creación de los mismos, o la optimización multi-objetivo junto con los procedimientos en streaming para crear la optimización multi-objetivo dinámica con el fin de poder abordar optimizaciones con grandes volúmenes de datos.

Con el objetivo de poner en relieve la relevancia de esta tesis, se muestra a continuación la lista de las publicaciones realizadas durante su desarrollo:

1. ***Fine Grain Sentiment Analysis with Semantics in Tweets*** [11]. Este artículo se realizó una primera aproximación al mundo del Big Data añadiéndole semántica al análisis de los datos. Se realizó un estudio de los sentimientos de los aficionados durante el torneo universitario de baloncesto de Estados Unidos *Big 12 Men's Basketball Championship*. En este artículo se comprobó de manera empírica, nuestra hipótesis, la semántica mejora y facilita el análisis en Big Data.
2. ***Dynamic Multi-Objective Optimization With jMetal and Spark: a Case Study*** [12]. El objetivo de este artículo fue comprobar que el uso de un framework de Big Data como Spark facilita la lectura de datos en streaming para su optimización. Es decir, se comprobó que era posible dotar con datos reales y en streaming a un problema de optimización.
3. ***Un Framework para Big Data Optimization Basado en jMetal y Spark*** [13]. En este trabajo se presenta una primera aproximación al framework para la optimización en Big Data, en el que se utiliza Spark como motor de computación distribuida y jMetal como motor de optimización.
4. ***jMetalSP: a framework for dynamic multi-objective big data optimization*** [14]. En este artículo se presenta la primera versión de jMetalSP, la herramienta para la optimización de Big Data. En esta primera versión jMetalSP está compuesto por una serie de algoritmos de optimización multi-objetivo y dinámicos. Se usa como caso de uso el problema de TSP con datos reales de la ciudad de Nueva York en streaming.
5. ***Multi-Objective Big Data Optimization with jMetal and Spark*** [15]. Con este trabajo se evalúa el rendimiento de jMetalSP y la plataforma de análisis con 100 nodos que hemos configurado para ejecutar todo el software desarrollado en esta tesis. Se comprueba la escalabilidad de la plataforma y del propio framework. Para ello se evalúan los tiempos de computación tratando con diferentes tamaños de datos y complejidad algorítmica del problema. Así como el número de nodos usados. Finalmente, una comparativa entre los framework MapReduce de Hadoop y Spark desde un punto de vista de tiempo de ejecución en algoritmos de optimización.
6. ***Design and Architecture of the jMetalSP Framework*** [16]. Este trabajo tiene como objetivo la presentación de una nueva arquitectura para jMetalSP en el que, ya no es tan dependiente de Spark, sino que se hace flexible a cualquier motor de ejecución paralela. Se añaden nuevos algoritmos dinámicos como Dynamic SMPPO y Dynamic MOCcell, así como la familia de problemas dinámicos FDA para su evaluación.
7. ***InDM2: Interactive Dynamic Multi-Objective Decision Making Using Evolutionary Algorithms*** [17]. En este artículo se presenta el primer algoritmo interactivo y dinámico de optimización multi-objetivo al que hemos llamado InDM2. El desarrollo de esta nueva propuesta algorítmica se ha realizado usando jMetalSP, por lo que añadimos a la plataforma algoritmos interactivos además de dinámicos.
8. ***BIGOWL: Knowledge Centered Big Data Analytics*** [18]. En este artículo se presenta BIGOWL, la propuesta ontológica para el análisis del Big Data. Define todos los componentes necesarios para el diseño, construcción y ejecución de un workflow. Así como los elementos de más bajo nivel que los conforman (algoritmos, problemas, datos, tareas, etc). Además se presentan una serie de consultas SPARQL y reglas de razonamiento para guiar el proceso de creación y validación de workflows. Se utiliza jMetalSP y el caso de uso del problema TSP con datos reales de la ciudad de Nueva York para validar el modelo semántico.
9. ***Análisis de datos de acelerometría para la detección de tipos de actividades*** [19]. Se realiza un estudio de viabilidad para la clasificación de actividades físicas obtenidas mediante pulseras de acelerometría en pacientes con problemas cardiovasculares, utilizando para ello algoritmos de *Deep Convolutional Neural Networks* (una modalidad de ConvNet) para un conjunto de datos de más de 4 TB.
10. ***Artificial Decision Maker Driven by PSO: An Approach for Testing Reference Point Based Interactive Methods*** [20]. Este trabajo presenta una serie de mecanismos para la evaluación de algoritmos interactivos de forma automática. Con esta aproximación es posible evaluar cualquier algoritmo interactivo que utilice puntos de referencias para indicar las preferencias del usuario. Esta propuesta se basa en la búsqueda del algoritmo PSO para encontrar buenas soluciones óptimas o cercanas a ellas. En nuestro caso, usamos la búsqueda de PSO para indicarle al algoritmo interactivo un punto de referencia cercano al punto de aspiración facilitado por el analista o Decision Maker.
11. ***Extending the Speed-constrained Multi-Objective PSO (SMPSO) With Reference Point Based Preference Articulation*** [21]. En este artículo presentamos una nueva versión interactiva del algoritmo SMPSO, usando el fra-

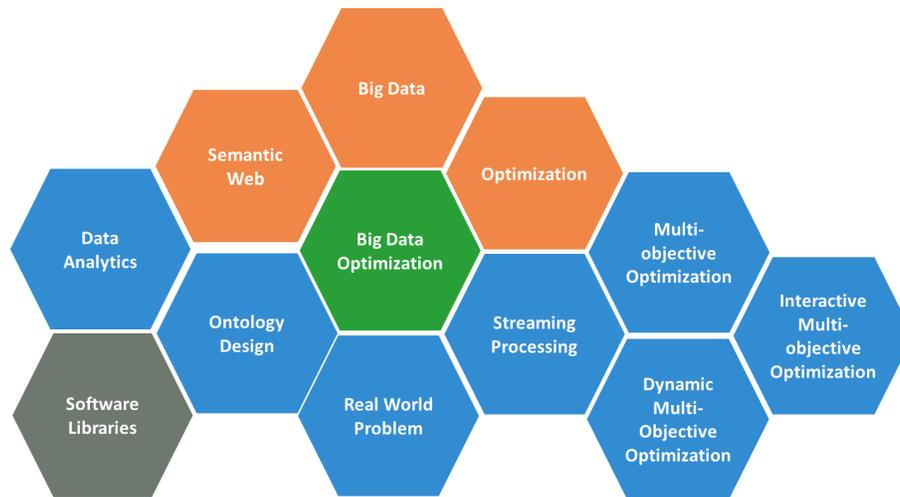


Figura 1. Líneas de investigación en la tesis.

mework jMetalSP. SMPSO con puntos de referencia puede centrarse solo en un área del espacio de búsqueda del problema especificado por el analista mediante los puntos de referencias, mejorando así los tiempos de ejecución ya que se reduce mucho el espacio de búsqueda.

12. **Scalable Inference of Gene Regulatory Networks with the Spark Distributed Computing Platform** [22]. En este trabajo resolvemos el problema biológico de la inferencia en redes génicas usando el jMetalSP ya que, gracias a Spark, se puede realizar computación distribuida y permite resolver este problema disminuyendo el tiempo de ejecución.
13. **About Designing an Observer Pattern-Based Architecture for a Multi-Objective Metaheuristic Optimization Framework** [23]. Este trabajo versa sobre la presentación de una nueva arquitectura para jMetal usando el patrón observador en el que se podrá componer metaheurísticas mediante componentes independientes y reusables. Por tanto, extendemos la idea de la composición de workflow a la composición de algoritmos.

En la Figura 2. se muestra un resumen de los diferentes trabajos antes mencionados junto con los tópicos de investigación que se cubren en esta tesis.

## VI. CONCLUSIONES

Las conclusiones que podemos destacar en esta tesis son:

- Esta tesis pretende abordar una serie de problemas actuales alineados con las prioridades estratégicas de los planes de investigación regional, nacional y europea.
- Se ha generado software, como son jMetalSP y BI-GOWL, que aportan valor a la comunidad científica y empresarial.
- Presenta una serie de contribuciones científicas bien avaladas en términos de publicaciones

Como futuras líneas de trabajo se pretende desarrollar nuevas propuestas algorítmicas que hagan uso del conocimiento

semántico que se pueda extraer del dominio de los problemas, facilitando así sus resoluciones.

## REFERENCIAS

- [1] M. Chen, S. Mao, and Y. Liu, "Big data: A survey," *Mobile networks and applications*, vol. 19, no. 2, pp. 171–209, 2014.
- [2] G.-H. Kim, S. Trimi, and J.-H. Chung, "Big-data applications in the government sector," *Communications of the ACM*, vol. 57, no. 3, pp. 78–85, 2014.
- [3] J. J. Durillo and A. J. Nebro, "jmetal: A java framework for multi-objective optimization," *Advances in Engineering Software*, vol. 42, no. 10, pp. 760–771, 2011.
- [4] M. Zaharia, M. Chowdhury, M. J. Franklin, S. Shenker, and I. Stoica, "Spark: Cluster computing with working sets," in *Proceedings of the 2Nd USENIX Conference on Hot Topics in Cloud Computing*, ser. HotCloud'10. USENIX Association, 2010, pp. 10–10.
- [5] K. Shvachko, H. Kuang, S. Radia, and R. Chansler, "The hadoop distributed file system," in *Mass storage systems and technologies (MSST), 2010 IEEE 26th symposium on*. Ieee, 2010, pp. 1–10.
- [6] V. Ojalehto, D. Podkopaev, and K. Miettinen, "Towards automatic testing of reference point based interactive methods," in *International Conference on Parallel Problem Solving from Nature*. Springer, 2016, pp. 483–492.
- [7] D. E. Avison, F. Lau, M. D. Myers, and P. A. Nielsen, "Action research," *Communications of the ACM*, vol. 42, no. 1, pp. 94–97, 1999.
- [8] C. B. Seaman, "Qualitative methods in empirical studies of software engineering," *IEEE Transactions on software engineering*, vol. 25, no. 4, pp. 557–572, 1999.
- [9] M. Bunge, "La investigación científica," *Ariel S.A.*, 1976.
- [10] P. Reason and H. Bradbury, *Handbook of action research: Participative inquiry and practice*. Sage, 2001.
- [11] C. Barba-González, J. García-Nieto, I. N. Delgado, and J. F. A. Montes, "A fine grain sentiment analysis with semantics in tweets," *IJIMAI*, vol. 3, no. 6, pp. 22–28, 2016.
- [12] J. A. Cordero, A. J. Nebro, C. Barba-González, J. J. Durillo, J. García-Nieto, I. Navas-Delgado, and J. F. Aldana-Montes, "Dynamic multi-objective optimization with jmetal and spark: a case study," in *LNCS of International Workshop on Machine Learning, Optimization and Big Data (MOD 2016)*. Springer, 2016, pp. 106–117.
- [13] C. Barba-González, A. J. Nebro, J. García-Nieto, J. A. Cordero, J. J. Durillo, I. Navas-Delgado, and J. F. Aldana-Montes, "Un framework para big data optimization basado en jmetal y spark," in *LNCS of XI Congreso Español de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB 2016)*, 2016, pp. 159–168.
- [14] C. Barba-González, J. García-Nieto, A. J. Nebro, J. A. Cordero, J. J. Durillo, I. Navas-Delgado, and J. F. Aldana-Montes, "jmetalsp: a framework for dynamic multi-objective big data optimization," *Applied Soft Computing*, vol. 69, pp. 737–748, 2017.

Journal or Congress/Topic	Big Data	Semantic Web	Optimization	Big Data Optimization	Data Analytics	Ontology Design	Real World	Streaming	MOP	DMOP	IMOP	Software Libraries
IJIMA(2016)[11]	✓				✓							
MOD (2016)[12]			✓				✓					
MAEB(2016)[13]			✓				✓					
Applied Soft Computing (2017)[14]			✓				✓					✓
EMO(2017)[15]			✓				✓					
GECCO(2017)[16]			✓				✓					✓
Swarm and Evolutionary Computation (2018)[17]			✓				✓				✓	✓
Expert Systems with Applications(2018) [18]			✓				✓				✓	✓
JISBD(2018)[19]												✓
PPSN(2018)[20]												✓
PPSN(2018)[21]												✓
IDC(2018)[22]												✓
IDC(2018)[23]												✓

Figura 2. Research contributions in this thesis.

- [15] C. Barba-González, J. García-Nieto, A. J. Nebro, and J. F. Aldana-Montes, "Multi-objective big data optimization with jmetal and spark," in *LNCS of International Conference on Evolutionary Multi-Criterion Optimization (EMO'17), GGS class 2 (CORE A)*. Springer, 2017, pp. 16–30.
- [16] A. J. Nebro, C. Barba-González, J. García-Nieto, J. A. Cordero, and J. F. A. Montes, "Design and architecture of the jmetaisp framework," in *Proceedings of the Genetic and Evolutionary Computation Conference Companion (GECCO'17)*. ACM, 2017, pp. 1239–1246.
- [17] A. J. Nebro, A. B. Ruiz, C. Barba-González, J. García-Nieto, M. Luque, and J. F. Aldana-Montes, "Indm2: Interactive dynamic multi-objective decision making using evolutionary algorithms," *Swarm and Evolutionary Computation*, vol. 40, pp. 184–195, 2018.
- [18] C. Barba-González, J. García-Nieto, M. d. M. Rodan-García, I. Navas-Delgado, and J. F. Aldana-Montes, "Bigowl: Knowledge centered big data analytics," *Expert Systems with Applications*, vol. 115, pp. 543–556, 2018.
- [19] S. Huratdo-Requena, C. Barba-González, M. Rybiński, F. J. Barón-López, J. Wärnberg, I. Navas-Delgado, and J. F. Aldana-Montes, "Análisis de datos de acelerometría para la detección de tipos de actividades," in *Jornadas de Ingeniería del Software y Bases de Datos (In press)*, 2018.
- [20] C. Barba-González, V. Ojalehto, J. García-Nieto, A. J. Nebro, K. Miettinen, and J. F. Aldana-Montes, "Artificial decision maker driven by pso: An approach for testing reference point based interactive methods," in *Proceeding of 15th International conference on parallel problem solving from nature (PPSN'18), GGS A class 2(CORE A)*. Springer, 2018, pp. 274–285.
- [21] A. J. Nebro, J. J. Durillo, J. García-Nieto, C. Barba-González, J. Del Ser, C. A. Coello Coello, A. Benítez-Hidalgo, and J. F. Aldana-Montes, "Extending the speed-constrained multi-objective pso (smpso) with reference point based preference articulation," in *Proceeding of 15th International conference on parallel problem solving from nature (PPSN'18), GGS A, CORE A*. Springer, 2018, pp. 298–310.
- [22] C. Barba-González, J. García-Nieto, A. J. Nebro, A. Benítez-Hidalgo, and J. F. Aldana-Montes, "Scalable inference of gene regulatory networks with the spark distributed computing platform," in *Springer Series of 12th International Symposium on Intelligent Distributed Computing (IDC'18)*, 2018.
- [23] A. Benítez-Hidalgo, A. J. Nebro, J. J. Durillo, J. García-Nieto, E. Camacho-López, C. Barba-González, B., and J. F. Aldana-Montes, "About designing an observer pattern-based architecture for a multi-objective metaheuristic optimization framework," in *12th International Symposium on Intelligent Distributed Computing*, 2018.



# Doctoral Consortium:

## Paralelización y adaptación de algoritmos de mantenimiento y detección de fallos a plataformas de cómputo en la nube

Mario Juez-Gil

Área de Lenguajes y Sistemas Informáticos, Departamento de Ingeniería Civil

Universidad de Burgos

Burgos, España

mariojg@ubu.es

**Resumen**—El incremento de los volúmenes de información con los que se trabaja en minería de datos, abre nuevas vías de investigación en ámbitos como la paralelización de algoritmos. Surgen también, nuevas posibilidades de aplicación en entornos industriales, como, por ejemplo, en tareas como mantenimiento y detección de fallos en entornos industriales. Este proyecto de tesis tiene como finalidad explorar y desarrollar técnicas de minería de datos paralelizables para su ejecución en arquitecturas paralelas como GPUs o plataformas de cómputo en la nube, para su posterior aplicación industrial.

**Index Terms**—Parallelism, cloud computing, CUDA, Map-Reduce, data mining, multi-label, ensembles, fault diagnosis

### I. DATOS

#### I-A. Datos de contacto

- Nombre y apellidos: Mario Juez Gil
- Dirección: Barriada Juan XXIII, nº 1, 8º, 3ª. 09007, Burgos
- Teléfono: +34 652213401
- Correo electrónico: mariojg@ubu.es
- LinkedIn: /mjuetz

#### I-B. Propuesta de título para la tesis

Paralelización y adaptación de algoritmos de mantenimiento y detección de fallos a plataformas de cómputo en la nube.

#### I-C. Directores

- César Ignacio García Osorio (cgosorio@ubu.es)
- Carlos López Nozal (clopezno@ubu.es)

#### I-D. Departamento

Departamento de Ingeniería Civil, Área de Lenguajes y Sistemas Informáticos, Universidad de Burgos.

#### I-E. Fecha de Inicio

7 de Marzo de 2018.

### II. RESUMEN

La minería de datos se centra en el estudio y tratamiento de grandes cantidades de datos para extraer conclusiones e información relevante y comprensible de conjuntos de datos para su uso posterior. Dos de las técnicas más comunes en la minería de datos son:

- Clasificación: Se asume que los datos pertenecen a distintas clases caracterizadas por los valores de sus atributos. El objetivo es construir clasificadores/modelos que asignen la etiqueta de la clase correcta a nuevas clases no etiquetadas.
- Regresión: En este caso, el atributo a determinar no es cualitativo o discreto (clase), sino numérico o continuo.

La aplicación de técnicas de minería de datos puede ser de utilidad en la mejora del mantenimiento y disponibilidad de maquinaria industrial. Utilizando los datos consistentes en las medidas tomadas por los sensores instalados en las máquinas, y la información de los históricos de las acciones de mantenimiento y reparación de averías, se puede asistir en la predicción de las averías y fallos, o incluso automatizar totalmente la predicción, permitiendo adelantar las acciones de preparación de recursos materiales y humanos para acometer el mantenimiento.

En este tipo de máquinas podrían ocurrir varias averías o fallos de forma simultánea (el fallo de un componente podría desencadenar fallos en otros componentes relacionados), por tanto, será necesario obtener varias predicciones (tantas como posibles componentes afectados) para un mismo conjunto de datos de entrada. En minería de datos, estos supuestos se conocen como problemas de salida múltiple o problemas de aprendizaje multietiqueta [1]–[3].

Las técnicas de clasificación multietiqueta y de regresión multivalor, aunque tienen un ámbito de aplicación amplio, su proceso de adopción está siendo lento. En el campo de las aplicaciones industriales apenas hay referencias. Entre las que conocemos, en [4] se utiliza la predicción multietiqueta para detección de fallos simultáneos en plantas químicas, y en [5]

en el campo de las perturbaciones en la calidad del suministro eléctrico. Sin embargo, en ningún caso nos constan trabajos de aplicación en la línea de los que propone el presente proyecto, lo que refuerza su carácter innovador.

Una forma de abordar los problemas de salida múltiple, es a través de la utilización de algoritmos de ensembles, los cuales permiten obtener predicciones mediante la combinación de varios modelos, homogéneos o heterogéneos [6]. Existe un consenso generalizado en que estos métodos son la mejor técnica para tratar los problemas más difíciles, ya que consiguen un mejor rendimiento frente al uso de un modelo único [7]–[9], además, el grupo de investigación en el que me encuentro desarrollando mi actividad investigadora, tiene amplia experiencia en el diseño de este tipo de métodos.

El tiempo de respuesta en tareas de predicción debe ser aceptable, no tendría sentido obtener el resultado de una predicción una vez que ya haya ocurrido el suceso a predecir. Cuando se trabaja con grandes volúmenes de datos, los tiempos de respuesta pueden ser elevados, por lo que se debe poner especial atención en tratar de reducirlos en la medida de lo posible.

La evaluación de posibilidades para mejorar el rendimiento de algoritmos de minería de datos a través de la paralelización de los mismos, es el objetivo principal de esta tesis. Este tipo de técnicas resulta interesante porque los algoritmos de ensembles son inherentemente paralelizables, cada clasificador base se puede entrenar de forma independiente en la mayoría de los métodos de construcción de ensembles (a excepción de *boosting* y sus derivados), para después combinar sus resultados. Pero es que, además, en el contexto de aprendizaje multietiqueta surgen nuevas oportunidades de paralelización y particionado de los procesos de cómputo. Por tanto, la paralelización de los algoritmos puede hacerse a varios niveles distintos, lo cual creemos que puede tener un impacto muy positivo en la reducción de los tiempos de respuesta. La paralelización de algoritmos también será especialmente relevante para poder ofrecer servicios de *Machine Learning as a Service* mediante la ejecución de los algoritmos desarrollados por el grupo de investigación en plataformas de computación paralela en la nube.

## II-A. Objetivos

La tesis tiene dos objetivos generales:

- Objetivo 1: Mejora de rendimiento de algoritmos para su explotación en tareas de mantenimiento y detección de fallos en entornos industriales.
- Objetivo 2: Facilitar el acceso a los algoritmos a través de servicios Web desplegados en plataformas de cómputo en la nube.

Como se ha descrito anteriormente, para mejorar la eficiencia y escalabilidad de los algoritmos, se utilizarán técnicas de paralelización. El primer objetivo general tiene los siguientes objetivos específicos:

- Subobjetivo 1.1: Adaptación de algoritmos para explotación de paralelismo mediante su ejecución en GPUs.

- Subobjetivo 1.2: Adaptación de algoritmos para explotación de paralelismo mediante su ejecución aplicando el modelo de cómputo *Map-Reduce*.

El segundo objetivo general, para poder ofrecer *Machine Learning as a Service*, plantea los siguientes objetivos específicos:

- Subobjetivo 2.1: Desarrollo de servicios Web (por ejemplo, APIs REST) que expongan interfaces públicas para permitir el uso de los algoritmos desarrollados.
- Subobjetivo 2.2: Integración de los algoritmos paralelizados con los servicios Web desarrollados mediante su ejecución en plataformas de cómputo en la nube.

## III. METODOLOGÍA Y PLAN DE TRABAJO

### III-A. Metodología

La paralelización de algoritmos consiste en desarrollar un *software*, por tanto, se seguirán los principios metodológicos de la Ingeniería del Software.

Debido a que este trabajo de investigación es una parte de un proyecto en el que participa el director, se seguirá su misma metodología para la extracción de conocimiento de los datos aplicando técnicas de aprendizaje automático, denominada *KDD process (Knowledge Discovery in Databases)* [10].

También se utilizarán metodologías de evaluación de rendimiento de los métodos desarrollados, haciendo uso de medidas para paralelización [11], y para clasificación multietiqueta y predicción multivalor, como, por ejemplo, las propuestas en [12], [13].

### III-B. Plan de trabajo

Este proyecto de tesis busca explorar principalmente dos tipos de esquemas de paralelización: esquemas basados en *Map-Reduce* en computación en la nube; y esquemas basados en paralelismo que ofrecen las GPUs. Adicionalmente también se estudiarán posibilidades híbridas que combinen ambos tipos de esquemas. Las fases previstas (o hitos) de la tesis serán las siguientes:

1. Estudio de bibliotecas de paralelización en GPUs.
2. Estudio de biblioteca Spark MLlib de paralelización *Map-Reduce*.
3. Desarrollo de prototipos e implantación en industria de algoritmos paralelos para GPU y Spark MLlib.
4. Evaluación y comparativa de resultados obtenidos con ambos esquemas de paralelización. Estudio de posibilidades de combinación de esquemas.
5. Adaptación de algoritmos desarrollados por el grupo de investigación a plataformas de cómputo paralelo en la nube.

A continuación, se describe con más detalle la finalidad de cada una de las fases:

*III-B1. Estudio de bibliotecas de paralelización en GPUs:* Las GPUs son un tipo de *hardware* inicialmente diseñado para el renderizado de gráficos e impulsado por la industria de los videojuegos. Sin embargo, actualmente es posible hacer uso de lenguajes de alto nivel para programar algoritmos que puedan



ser ejecutados en arquitecturas GPU gracias a bibliotecas como CUDA de NVIDIA [14]. Existen artículos [15], [16] donde se aboga por la paralelización en GPUs como la mejor solución para conseguir algoritmos de minería de datos y aprendizaje automático más eficientes. En esta fase del trabajo de investigación se estudiarán bibliotecas como CUDA [17] o OpenCL [18], así como las posibilidades existentes para su uso con algoritmos de ensembles y aprendizaje multitiqueta.

*III-B2. Estudio de biblioteca de Spark MLlib de paralelización Map-Reduce:* Uno de los paradigmas de computación paralela más populares es *Map-Reduce* [19], implementaciones como Spark (<https://spark.apache.org/>) permiten incrementar el rendimiento de algoritmos de minería de datos y aprendizaje automático. Una búsqueda en Google del término «*spark machine learning*» arroja más de cuatro millones de resultados, y muestra que MLlib (<https://spark.apache.org/mllib/>) es la biblioteca donde parece obligado proporcionar implementaciones de los algoritmos desarrollados por el grupo, si se quiere aumentar el impacto que éstos puedan tener en la comunidad científica. En esta fase del trabajo de investigación se estudiará la biblioteca MLlib y las posibilidades existentes para su uso con algoritmos de ensembles y aprendizaje multitiqueta.

*III-B3. Desarrollo de prototipos e implantación en industria de algoritmos paralelos para GPU y Spark MLlib:* Tras adquirir los conocimientos necesarios sobre el funcionamiento de los dos esquemas principales de paralelización de algoritmos y sus bibliotecas, se llevarán a la práctica mediante el desarrollo de prototipos de algoritmos de minería de datos paralelos que puedan ser implantados en entornos industriales. La finalidad de esta fase es doble: por un lado se buscará demostrar la validez de nuestros algoritmos paralelos en tareas de mantenimiento y detección de fallos en entornos industriales, a través de publicaciones en revistas científicas; mientras que por otra parte, también se pretende compartir los conocimientos adquiridos con el resto de miembros del grupo de investigación.

Los prototipos también serán útiles para evaluar el rendimiento de ambos paradigmas en fases futuras.

*III-B4. Evaluación y comparativa de resultados obtenidos con ambos esquemas de paralelización. Estudio de posibilidades de combinación de esquemas:* Los prototipos desarrollados se evaluarán teniendo en cuenta distintas medidas de rendimiento. Tras la evaluación se hará una comparativa entre los resultados obtenidos empleando paralelización en GPU, y aquellos obtenidos empleando Spark MLlib, con el fin de escoger el esquema con mejor rendimiento para su posterior aplicación en tareas de mantenimiento y detección de fallos en entornos industriales. Para medir el rendimiento de los algoritmos desarrollados se tendrá en cuenta tanto su naturaleza paralela, como multitiqueta. Por ello se utilizarán métricas como rapidez (*speedup*) o eficiencia [11] para el primer caso, y métricas como *F measure*, precisión, o *Hamming loss* [12], [13] para el segundo.

En esta fase también se estudiarán las posibilidades existentes para combinar ambos esquemas de paralelización, como,

Cuadro I  
HITOS DE LA TESIS

Hito	Objetivo	Descripción
1	1	<b>Estudio bibliotecas de paralelización</b>
	1.1	Estudio bibliotecas GPU
	1.2	Estudio bibliotecas Spark
2	1	<b>Desarrollo de prototipos e implantación industrial</b>
	1.1	Implementación de prototipo GPU
	1.1	Publicación proponiendo la implantación del prototipo GPU en entornos industriales
	1.2	Implementación de prototipo Spark MLlib
	1.2	Publicación proponiendo la implantación del prototipo Spark MLlib en entornos industriales
3	1	<b>Evaluación y comparativa de resultados</b>
	1.1	Evaluación prototipo GPU
	1.2	Evaluación prototipo Spark MLlib
	1.1, 1.2	Comparativa resultados GPU vs MLlib
	1.1, 1.2	Estudio posibilidad híbrida GPU + Spark
4	2	<b>Adaptación de algoritmos del grupo a la nube</b>
	2.1	Desarrollo de servicios web públicos
	2.2	Integración de algoritmos con servicios web

por ejemplo, la ejecución de Spark en GPUs propuesta por [20].

*III-B5. Adaptación de algoritmos desarrollados por el grupo de investigación a plataformas de cómputo paralelo en la nube:* Recientemente han surgido diversas plataformas de cómputo en la nube, entre las que destacan Google Cloud Platform, Amazon AWS, o Microsoft Azure. Este tipo de plataformas permite configurar agrupaciones (*clusters*) de cómputo con un número de nodos personalizado, lo cual es de gran utilidad para la ejecución de algoritmos paralelos de minería de datos. Surgen así, posibilidades para ofrecer como servicio (*Machine Learning as a Service*) los algoritmos y tecnologías desarrollados por el grupo, de manera que puedan ser utilizados fácilmente por empresas que necesiten de estos servicios. En esta fase del trabajo de investigación se adaptarán los algoritmos de minería de datos del grupo para su ejecución en plataformas de cómputo en la nube a través de servicios públicos, como por ejemplo APIs REST [21].

### III-C. Hitos

Los hitos de la tesis y su relación con los objetivos se describen en la Tabla I.

La tabla está dividida en cuatro secciones, cada una de las cuales se corresponde con un hito general. La segunda columna indica sobre qué objetivo/subobjetivo de los descritos en II-A se está trabajando. La última columna es una breve descripción del hito.

## IV. RELEVANCIA

Trabajar con cantidades de datos cada vez mayores es una tendencia imparable en la actualidad. Surgen por tanto, nuevos retos científicos, como, por ejemplo, la necesidad de una evolución de las técnicas existentes de minería de datos para que sean escalables y capaces de manejar grandes volúmenes de información. Dicho objetivo se puede conseguir mediante la paralelización de estos algoritmos, utilizando modelos ya

existentes como *Map-Reduce* o desarrollando nuevas soluciones paralelas en GPUs.

Nuestra investigación ofrece además, posibilidades de aplicación en la industria, concretamente en tareas como la detección temprana de fallos en maquinaria industrial, donde optimizar el tiempo de respuesta de los algoritmos, o aplicar técnicas multitiqueta (por ejemplo, para la predicción de múltiples combinaciones de fallos), puede tener un impacto muy positivo.

- [20] P. Li, Y. Luo, N. Zhang, and Y. Cao, "HeteroSpark: A heterogeneous CPU/GPU Spark platform for machine learning algorithms," in *2015 IEEE International Conference on Networking, Architecture and Storage (NAS)*, 2015, pp. 347–348.
- [21] M. Masse, *REST API Design Rulebook: Designing Consistent RESTful Web Service Interfaces*. O'Reilly Media, Inc., 2011.

## REFERENCIAS

- [1] E. Gibaja and S. Ventura, "Multi-label learning: a review of the state of the art and ongoing research," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 4, no. 6, pp. 411–444, nov 2014. [Online]. Available: <http://doi.wiley.com/10.1002/widm.1139>
- [2] —, "A Tutorial on Multilabel Learning," *ACM Computing Surveys*, vol. 47, no. 3, pp. 1–38, apr 2015. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2737799.2716262>
- [3] G. Madjarov, D. Kocev, D. Gjorgjevikj, and S. Džeroski, "An extensive experimental comparison of methods for multi-label learning," *Pattern Recognition*, vol. 45, no. 9, pp. 3084–3104, 2012.
- [4] I. Yélamos, M. Graells, L. Puigjaner, and G. Escudero, "Simultaneous fault diagnosis in chemical plants using a multilabel approach," *AICHE Journal*, vol. 53, no. 11, pp. 2871–2884, 2007.
- [5] Z. Liu, Y. Cui, and W. Li, "A classification method for complex power quality disturbances using EEMD and rank wavelet SVM," *IEEE Transactions on Smart Grid*, vol. 6, no. 4, pp. 1678–1685, 2015.
- [6] L. I. Kuncheva, *Combining Pattern Classifiers: Methods and Algorithms*. New York, NY, USA: Wiley-Interscience, 2004.
- [7] E. Bauer and R. Kohavi, "An empirical comparison of voting classification algorithms: Bagging, boosting, and variants," *Machine learning*, vol. 36, no. 1, pp. 105–139, 1999.
- [8] O. Maimon and L. Rokach, *Data Mining and Knowledge Discovery Handbook*, 2nd ed. Springer Publishing Company, Incorporated, 2010.
- [9] G. I. Webb, "Multiboosting: A technique for combining boosting and wagging," *Machine learning*, vol. 40, no. 2, pp. 159–196, 2000.
- [10] U. M. Fayyad, G. Piatetsky-Shapiro, P. Smyth, and R. Uthurusamy, Eds., *Advances in Knowledge Discovery and Data Mining*. Menlo Park, CA, USA: American Association for Artificial Intelligence, 1996.
- [11] J. Jája, *An Introduction to Parallel Algorithms*. Redwood City, CA, USA: Addison Wesley Longman Publishing Co., Inc., 1992.
- [12] H. Borchani, G. Varando, C. Bielza, and P. Larrañaga, "A survey on multi-output regression," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 5, no. 5, pp. 216–233, sep 2015. [Online]. Available: <http://doi.wiley.com/10.1002/widm.1157>
- [13] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427–437, jul 2009. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0306457309000259>
- [14] L. Jian, C. Wang, Y. Liu, S. Liang, W. Yi, and Y. Shi, "Parallel data mining techniques on Graphics Processing Unit with Compute Unified Device Architecture (CUDA)," *The Journal of Supercomputing*, vol. 64, no. 3, pp. 942–967, jun 2013. [Online]. Available: <http://link.springer.com/10.1007/s11227-011-0672-7>
- [15] J. Nickolls and W. J. Dally, "The GPU Computing Era," *IEEE Micro*, vol. 30, no. 2, pp. 56–69, mar 2010. [Online]. Available: <http://ieeexplore.ieee.org/document/5446251/>
- [16] D. Singh and C. K. Reddy, "A survey on platforms for big data analytics," *Journal of Big Data*, vol. 2, no. 1, p. 8, dec 2015. [Online]. Available: <http://www.journalofbigdata.com/content/2/1/8>
- [17] Nvidia, "Nvidia cuda c programming guide," 01 2010.
- [18] J. E. Stone, D. Gohara, and G. Shi, "OpenCL: A Parallel Programming Standard for Heterogeneous Computing Systems," *Computing in Science & Engineering*, vol. 12, no. 3, pp. 66–73, may 2010. [Online]. Available: <http://ieeexplore.ieee.org/document/5457293/>
- [19] J. Dean and S. Ghemawat, "MapReduce," *Communications of the ACM*, vol. 51, no. 1, p. 107, jan 2008. [Online]. Available: <http://portal.acm.org/citation.cfm?doid=1327452.1327492>



# Neuroevolución Profunda: Aplicaciones en Ciudades Inteligentes

Andrés Camero\*, Enrique Alba†

Universidad de Málaga, Departamento de Lenguajes y Ciencias de la Computación

\*Doctorando, andrescamero@uma.es

†Director, eat@lcc.uma.es

**Resumen**—En la última década la aparición del Deep Learning y las redes neuronales profundas ha revolucionado la sociedad. Cada vez son más las aplicaciones que hacen uso de ella, desde coches autónomos, hasta asistentes robotizados. Sin embargo, a medida que estas redes crecen, nos enfrentamos a nuevos desafíos. Un problema particular es la búsqueda de una configuración o hiperparámetro óptima, es decir encontrar la red que mejor se adapta a un problema dado. Se han propuesto diversos enfoques para abordar la hiperparametrización, pero en la práctica pocos han sido adoptados por el excesivo tiempo de cómputo que requieren. No obstante, en los últimos años ha surgido un nuevo acercamiento: la neuroevolución profunda. Basándose en el uso de metaheurísticas avanzadas, ésta ofrece una nueva forma de solucionar el problema, la cual está permitiendo encontrar soluciones sin precedentes y en tiempos cada vez más razonables, abriendo el camino a su adopción práctica. En este trabajo presentamos un proyecto de investigación para abordar el problema de la optimización de la hiperparametrización de una red neuronal recurrente, un tipo de red profunda especialmente buena para resolver problemas que requieran aprender dependencias temporales. Concretamente, proponemos una solución basada en la neuroevolución profunda, la cual validaremos usando tres problemas en el contexto de la ciudad inteligente.

**Index Terms**—Deep neuroevolution, Deep learning, Hyperparameter optimization, Recurrent neural network, Smart City

## I. INTRODUCCIÓN

En las últimas décadas, gracias al vertiginoso aumento de la potencia de cómputo y almacenamiento de datos, se ha evidenciado un resurgimiento del interés por desarrollar redes neuronales artificiales (ANN). Las “antiguas” técnicas, combinadas con esta nueva potencia computacional han permitido obtener resultados sorprendentes: desde coches autónomos, hasta asistentes personales robotizados [1].

En gran medida este resurgimiento ha sido impulsado por el *Deep Learning* (DL) [1] (aprendizaje profundo), que en términos simples consiste en diseñar y entrenar ANN (“lo antiguo”) de mayor complejidad y tamaño, con una cantidad de datos inmensa (“lo nuevo”). Sin embargo, a medida que estas redes crecen se vuelven más complejas, lo que plantea un nuevo desafío: ¿Cómo diseñamos una ANN profunda? Tradicionalmente el diseño de las ANN ha sido tarea de un experto, quien basado en su conocimiento, en técnicas y herramientas específicas, y en un arduo trabajo de prueba y error diseña una ANN que se adapta de buena forma al problema. Sin embargo, debido a la elevada complejidad de las ANN profundas (¡millones de parámetros!), esta forma de diseñar se torna ineficiente. La situación empeora conforme la cantidad de datos usados para entrenar la red crece, luego sólo el entrenamiento de una ANN profunda puede tardar días, por lo que un diseño óptimo puede tardar meses [2].

Dada la especial importancia que tiene encontrar un diseño óptimo (o hiperparametrización de la ANN) en el desempeño global, incluyendo tanto el resultado como el proceso de aprendizaje, se han realizado numerosas propuestas para automatizar la búsqueda de una solución [2]. Sin embargo, una amplia mayoría de las propuestas basa su funcionamiento en la prueba y el error, es decir se escoge un diseño, se entrena la red y se evalúa su resultado. Si bien este enfoque es capaz de entregar buenas soluciones, es muy costoso, por lo que en la práctica es poco utilizado. Una solución intuitiva para este tipo de técnicas consiste en limitar el esfuerzo del entrenamiento (i.e. terminar el entrenamiento de manera precoz), lo cual permite reducir significativamente el tiempo. No obstante, dada la elevada complejidad de los diseños de las ANN profundas, es posible que un buen diseño sea descartado debido a que es de lento aprendizaje.

Como solución alternativa al problema de la hiperparametrización surge la *Deep Neuroevolution* [3]–[5] (DN) (neuroevolución profunda), un conjunto de técnicas que permiten evolucionar el diseño de una ANN profunda, es decir la adaptación de la “antigua” neuroevolución [6] a los desafíos del DL. Utilizando metaheurísticas (e.g algoritmos genéticos, colonias de hormigas, recocido simulado, etc.) es posible navegar a través del espacio de diseños, encontrando así uno que se adapta de mejor manera al problema. Si bien a primera vista este también es un enfoque de prueba y error, existe una gran diferencia: la DN es una búsqueda dirigida que explota las características topológicas del problema y no se basa (necesariamente) en el entrenamiento de la red. Por lo tanto, la DN abre un camino que se espera permita mejorar los resultados actuales.

En este trabajo presentamos nuestro acercamiento a la DN, mostrando a través de aplicaciones reales en el dominio de la *Smart City* (SC) (ciudad inteligente) su desempeño en contraste con el estado del arte de la hiperparametrización. Concretamente, presentamos un plan de trabajo para el desarrollo de una tesis doctoral que busca contribuir en la hiperparametrización de una red neuronal recurrente (RNN), un tipo de ANN profunda que incluye conexiones neuronales que retroalimentan a la misma red, mediante técnicas de DN.

El resto de este trabajo se organiza de la siguiente forma: la siguiente sección esboza el estado del arte, la Sección III presenta nuestra propuesta, la Sección IV introduce el plan de trabajo, la Sección V presenta una discusión sobre la relevancia de nuestra propuesta y en la Sección VI presentamos las conclusiones preliminares del avance del trabajo.

## II. ESTADO DEL ARTE

En esta sección presentamos brevemente el contexto actual de las ANN profundas. Primero revisamos su historia, del pasado al presente, luego nos centramos en el DL, para finalmente introducir el estado del arte en la hiperparametrización de ANN profundas.

### II-A. Redes Neuronales Artificiales

El cerebro humano es una “máquina” capaz de realizar tareas muy complejas, como el reconocimiento de patrones, el control motriz de una extremidad o la percepción de estímulos sensitivos, de forma mucho más veloz que cualquier máquina inventada por el hombre [7]. Por este motivo se han (y siguen haciendo) realizado grandes esfuerzos para comprender su funcionamiento [8], [9].

Esta “máquina” está formada por cerca de 100 billones de neuronas (células del sistema nervioso especializadas en la recepción y conducción de estímulos), las cuales se comunican entre sí, formando complejos circuitos, los cuales son capaces de llevar a cabo la función cerebral [9]. Este modelo biológico fue la inspiración para que en 1943 McCulloch y Pitts [10] propusieran un nuevo modelo computacional: la ANN.

Una ANN es una red de unidades de cómputo (neuronas) comunicadas (o conectadas) entre sí, donde cada unidad realiza un cálculo a partir de una entrada y comunica su resultado (salida) a las unidades conectadas. Típicamente las conexiones reciben un peso, el cual indica que tan fuerte es la conexión entre dos unidades. Asimismo, las unidades de cómputo suelen agruparse en módulos o capas. Las ANN presentan propiedades y capacidades que son muy útiles para la resolución de problemas complejos, destacándose su no linealidad (*nonlinearity*), adaptatividad, tolerancia a fallos, entre otros [7]. Gracias a estas propiedades se ha logrado superar los resultados obtenidos en múltiples problemas.

Las ANN despertaron un gran interés y se desarrollaron rápidamente, sin embargo las primeras décadas de su evolución se vieron marcadas por técnicas que requerían de un gran esfuerzo para diseñar la ANN y de un amplio conocimiento del dominio del problema para transformarlo en algo que la ANN pudiese procesar [1], [11]. No fue sino hasta mediados de la década de 1980, cuando tomando como base el método *stochastic gradient descent*, se logró plantear (y comprender) como reducir la intervención humana: el método *backpropagation* (BP) [12], [13].

BP es un procedimiento para computar el gradiente de una función objetivo (*loss function*) con respecto a los pesos de una ANN [13]. Este método en una aplicación práctica de la *regla de la cadena*, cuyo eje central es que el gradiente de una función objetivo con respecto a la entrada de una capa (de neuronas) puede ser calculado de atrás hacia adelante a partir del gradiente de la salida de la misma capa. Esto permite propagar desde la salida hacia la entrada el error, ajustando así los pesos de la red.

Luego de más de una década de estudio (a fines de 1990), el método *backpropagation* y las ANN en general fueron dejadas de lado, debido a que se pensó que en la práctica no era posible

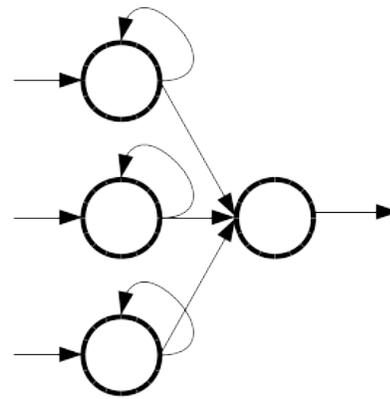


Figura 1. Red neuronal recurrente.

*aprender* conceptos complejos a partir de escasa información previa [1], o en otras palabras no se sabía cómo entrenar una ANN de múltiples capas ocultas que fuese capaz de modelar funciones no lineales altamente variables [14]. Sin embargo, casi una década después (a mediados de la década de 2000), gracias a la contribución de Hinton et al. [15], el interés por las ANN resurgió de la mano de un nuevo concepto: el DL.

### II-B. Deep Learning

DL es un tipo de aprendizaje de máquina que permite entrenar ANN compuestas de múltiples capas ocultas, conocidas como ANN profundas (*deep neural network*, DNN) [1]. La teoría de circuitos sugiere que mientras más profunda sea la arquitectura de una ANN, más eficiente será en términos del número de elementos computacionales requeridos para representar funciones altamente no lineales y variantes [14].

Existen múltiples tipos de DNN: *feedforward* (FNN) [16], *radial-basis* [17], *recurrent* (RNN) [7], *modular* [17], [18], entre otros [7]. Particularmente, las RNN se caracterizan por propagar la información hacia adelante (al igual que las FNN) y por incluir al menos una conexión hacia atrás (retroalimentación *feedback*). Este *feedback* puede ser de una neurona sobre sí misma (*self-feedback*) o sobre otras neuronas. Asimismo, puede originarse desde las capas ocultas o desde la salida de la RNN. Por su arquitectura las RNN son en esencia las DNN de mayor profundidad.

La Figura 1 muestra una RNN. Gracias a las conexiones hacia atrás, las RNN son capaces de presentar un comportamiento dinámico no lineal [7].

A medida que la DNN se vuelve más compleja el número de parámetros crece. En términos simples, más neuronas implica más pesos, a más capas ocultas mayor no linealidad (más dificultad al propagar un error, e.g. BP), y en el caso de las RNN, la retroalimentación agrega más pesos y profundidad, es decir empeora aún más la situación. Luego, considerando la importancia que tiene la selección de un diseño apropiado de la DNN para la obtención de buenos resultados [2], se hace mandatorio abordar la hiperparametrización de manera inteligente.



## II-C. Hiperparametrización

El problema de hiperparametrizar u optimizar una ANN consiste en encontrar una estructura de red, que incluye la selección del tipo de neuronas apropiadas (i.e. función de activación, memoria, etc.), el número de neuronas y su disposición (número de capas y conexiones), y un conjunto de pesos que permitan minimizar una función objetivo [2].

Existen múltiples algoritmos, técnicas y procedimientos que permiten abordar dicho problema, así como también diferentes enfoques, que consideran una de las *dimensiones* (estructura o pesos) o ambas a la vez [7].

Los métodos más populares en este contexto son BP [13] y *conjugate gradient* [19] (y sus variantes [2]). Ambos métodos permiten optimizar los pesos de una ANN con muy buenos resultados, sin embargo en problemas de alta dimensionalidad, es decir en el caso de DNN, los dos métodos tienen una tendencia a estancarse en mínimos locales y -especialmente- en mesetas [20]. Dado lo anterior y considerando que ambos métodos sólo se centran en la optimización de los pesos (recordemos que a mayor profundidad de una red, mayor es su eficiencia [14]) es necesario explorar otras alternativas que permitan optimizar una DNN en todas sus dimensiones.

En la búsqueda de alternativas a BP, Engel [21] propuso en la década de 1980 optimizar los pesos de una FNN aplicando la técnica del recocido simulado (*simulated annealing*, SA). Casi simultáneamente, Montana y Davis [22] propusieron utilizar un algoritmo genético (GA) para optimizar los pesos de una FNN. Los buenos resultados obtenidos impulsaron la investigación en la materia (metaheurísticas aplicadas a la optimización de ANN) [2], [23], incluyendo tanto soluciones para la optimización de los pesos [24], [25], como para la optimización de la arquitectura y los pesos de manera simultánea [26], [27]. Asimismo se desarrolló un nuevo paradigma llamado *neuroevolución* (*neuroevolution*) [6], el cual considera la evolución de los componentes de la NN como parte fundamental de la misma, además del aprendizaje, dando origen a las *ANN evolutivas*.

Sin embargo, el surgimiento de las DNN, sumado al creciente volumen de datos, y a la heterogeneidad y sofisticación de los dispositivos tecnológicos que depara la *cuarta revolución industrial*, ha abierto la puerta a nuevas oportunidades para la optimización de las DNN. Es necesario contar con DNN simples, es decir es necesario optimizar los pesos y la arquitectura, y *adaptables*, ya que las necesidades e incluso las fuentes de datos cambian, así como con métodos de optimización que sean *eficientes*, en términos de su capacidad de actuar con la menor cantidad de datos y en el menor tiempo. Por todo esto, y en atención a las limitaciones de BP (principalmente a que sólo optimiza los pesos) y a los prometedores resultados obtenidos por las metaheurísticas en esta problema, con las condiciones actuales [25], estas últimas se presentan como buenas candidatas para aprovechar las oportunidades.

### III. PROPUESTA: NEUROEVOLUCIÓN PROFUNDA

Considerando las oportunidades expuestas y el estado del arte, proponemos abordar el problema de la hiperparametriza-

ción de DNN mediante la DN, prestando especial atención en las RNN (por ser intrínsecamente las ANN más profundas).

Definimos como objetivo del trabajo de tesis el desarrollo de una técnica de DN *híbrida*, es decir que utilice tanto métodos *tradicionales* (como BP), como técnicas basadas en metaheurísticas. De este modo buscamos aprovechar las bondades de ambas estrategias, con el fin de obtener el mejor resultado posible.

Particularmente, centraremos nuestro trabajo en el estudio de las propiedades intrínsecas de las RNN, esto es buscaremos una manera simple de caracterizar la arquitectura de una red (configuración concreta de hiperparámetros que no considera los valores de los pesos), que permita comparar dos configuraciones de manera tal que sea posible determinar cuál de ellas se adapta mejor a un problema dado. Luego, usaremos esta información como entrada (la “heurística”) para definir un algoritmo metaheurístico de optimización de RNN. Finalmente, una vez escogida la mejor red para el problema, proponemos entrenar esta red con métodos del estado del arte. Es importante notar que de manera tentativa no limitamos el entrenamiento a BP ni al uso de metaheurísticas, sino que buscaremos la mejor forma de resolver el problema.

La siguiente lista enumera los objetivos principales del presente trabajo doctoral:

- G1 Definir un método para caracterizar RNN que permita comparar su desempeño esperado sin la necesidad de realizar un entrenamiento de la misma.
- G2 Diseñar e implementar una técnica de hiperparametrización de RNN basada en metaheurísticas que utilice la caracterización definida previamente.
- G3 Aplicar la técnica de hiperparametrización de RNN definida a la resolución de problemas en el contexto de SC.
- G4 Difundir los resultados mediante el desarrollo (y la puesta a disposición pública) de una librería software.

Cabe señalar que como parte de las directrices de este trabajo, proponemos utilizar la herramienta *TensorFlow* [28], una librería de código abierto para el aprendizaje de máquina utilizada (y desarrollada inicialmente) por Google. La idea de fondo es, además de reutilizar la implementación de la DNN, maximizar el impacto del objetivo G4.

### IV. METODOLOGÍA Y PLAN DE TRABAJO

Para cumplir con los objetivos propuestos planteamos realizar un estudio teórico y empírico de la hiperparametrización de una RNN. Además de diseñar y construir artefactos de software que permitan implementar los algoritmos definidos, para luego aplicarlos a la resolución de problemas reales en los dominios establecidos.

Este trabajo tendrá una duración planificada de 36 meses y se definen 6 paquetes de trabajo (WP) para cumplir con los objetivos definidos. A continuación se describen los WP del proyecto:

- WP0 Gestión del Proyecto: Actividades relacionadas al control y planificación del proyecto, así como las

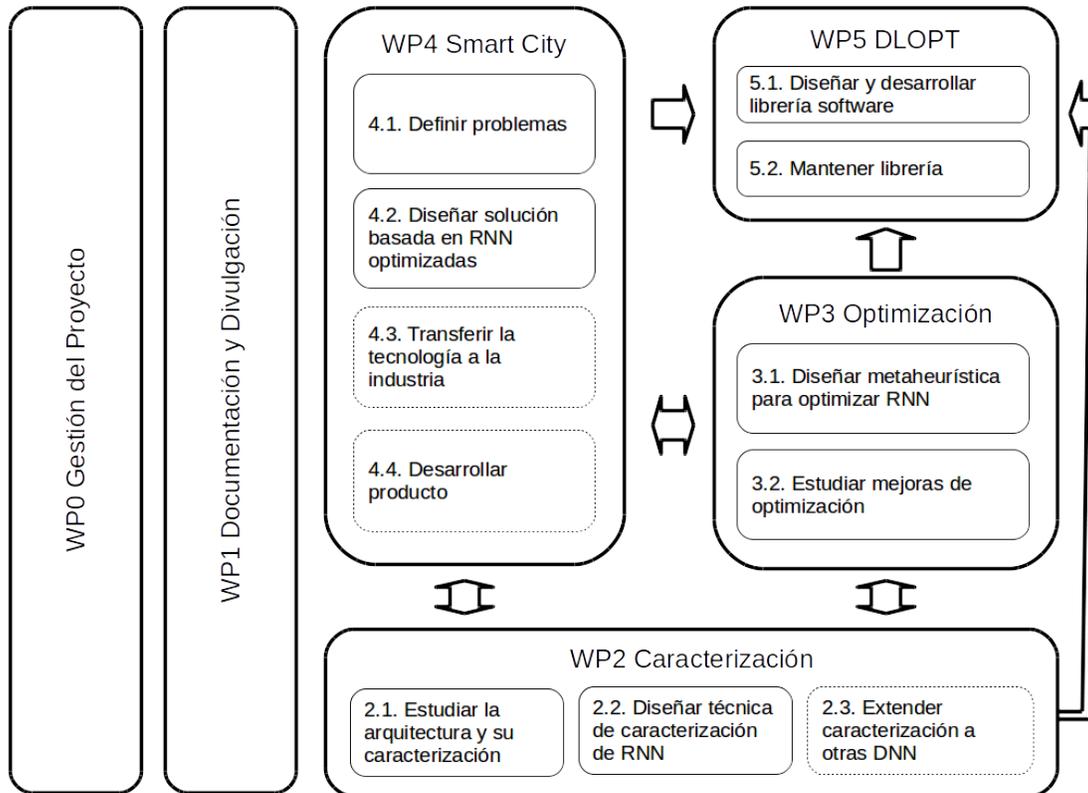


Figura 2. Paquetes de trabajo, sus actividades principales y relaciones.

actividades burocráticas requeridas para su presentación.

- WP1 Documentación y Divulgación: Generación de la tesis doctoral y actividades relativas a la promoción de los resultados.
- WP2 Caracterización: Actividades conducentes al desarrollo de una caracterización de la arquitectura de una RNN (objetivo **G1**).
- WP3 Optimización: Desarrollo de una técnica para la optimización de los hiperparámetros de una RNN basada en metaheurísticas y en la caracterización definida (objetivo **G2**).
- WP4 Smart City: Agrupación de actividades relativas al estudio de tres problemas reales en el contexto de la SC y su resolución mediante el uso de una RNN optimizada con la técnica definida (objetivo **G3**). Como parte de esta actividad se definirán los problemas concretos que serán abordados.
- WP5 DLOPT: Actividades relacionadas al desarrollo y mantenimiento de una librería software que incorpore los resultados del trabajo (objetivo **G4**).

Los paquetes **WP0** y **WP1** son funciones de apoyo a la tesis doctoral y por tanto su ciclo de vida está ligado a la duración del mismo. La Figura 2 muestra los paquetes de trabajo y sus actividades principales, así como la relación que existe entre los diferentes paquetes. Las actividades que aparecen con líneas punteadas son consideradas optativas para

la consecución del objetivo.

La Figura 3 muestra la planificación de alto nivel, incluyendo los hitos más relevantes de cada paquete de trabajo (destacados en color naranja en el calendario). La Sección IV-A muestra con un mayor nivel de detalle la planificación del paquete de trabajo **WP1**.

#### IV-A. Diseminación de los resultados

Con el fin de difundir los resultados de este trabajo y con el objetivo de establecer nexos que permitan contribuir a los mismos se plantea publicar artículos científicos en revistas especializadas, asistir y publicar en congresos relevantes, y desarrollar una página web temática.

Consideraremos al menos las siguientes revistas para la publicación de los resultados obtenidos (entre paréntesis se muestra la clasificación y calificación en el ranking JCR<sup>1</sup>): Engineering Applications of Artificial Intelligence (Computer Science, Artificial Intelligence, Q1), Applied Soft Computing (Computer Science, Software, Q1) y Energies (Energy and Fuels., Q2).

Asimismo tendremos en cuenta los siguientes congresos: Congress on Evolutionary Computation (CEC, IEEE), The Genetic and Evolutionary Computation Conference (GECCO, ACM), EvoStar y Conference on Neural Information Processing Systems (NIPS, IEEE).

<sup>1</sup><http://www.scimagojr.com> [Accedido: 22-Agosto-2017]

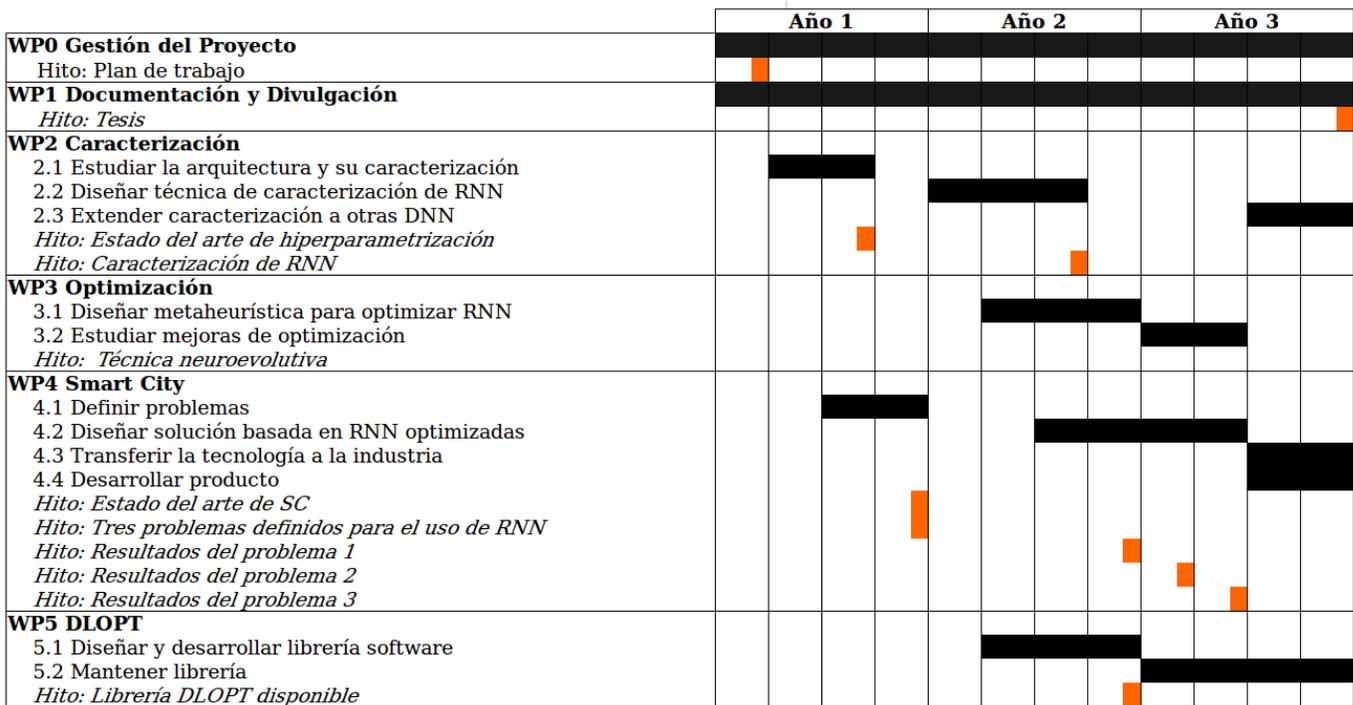


Figura 3. Plan de alto nivel. En negro se destacan los hitos más relevantes del trabajo.

Por otra parte, el sitio web temático será publicitado a través de los medios de difusión del grupo de investigación.

A la fecha, se cuenta con 3 artículos aceptados en conferencias [3], [29], [30] y 2 artículos en revisión (ya están disponibles de manera pública como *preprints*) [31], [32] relacionados con la propuesta de caracterización de RNN y su uso. Asimismo se han publicado 2 artículos en revistas de calidad [33], [34] y 1 en un congreso internacional [35] relacionados a los problemas de SC escogidos (pero no ligados a RNN). A estos trabajos se suman otros trabajos en progreso y en revisión (no disponibles públicamente).

## V. RELEVANCIA

Este trabajo se centra en la resolución de un problema concreto: la hiperparametrización de una RNN, que si bien ya cuenta con múltiples soluciones propuestas, todavía es posible avanzar en la obtención de mejores resultados [2]. Asimismo, proponemos utilizar nuestros avances para la resolución de tres problemas en el contexto de las SC. Por este motivo, y dada la naturaleza y la relevancia de los problemas concretos [36], se espera que los resultados de este trabajo tengan un impacto positivo en la sociedad.

Esperamos también que los resultados de este trabajo, especialmente lo referido a los objetivos G1 y G2, sean de utilidad para la resolución del problema en otros tipos de DNN. Lo cual permitiría aumentar el impacto del trabajo considerablemente. Por este motivo, dependiendo del tiempo disponible y de los resultados obtenidos, planteamos nuestra intención de investigar en esa línea.

Por otra parte, el concepto de DN es reciente, por lo cual esperamos contribuir a su cimentación. No solo haciendo uso del conocimiento actual, sino que también aprovechando la experiencia del equipo en neuroevolución [23].

Finalmente, en lo referido al impacto más tangible de este trabajo (objetivo G4), esperamos contribuir activamente a la mejora de los resultados de los diversos usos que hoy en día se hacen de las RNN. Lo cual será una especie de efecto colateral de nuestro trabajo.

## VI. CONCLUSIONES

En este trabajo hemos presentado nuestra propuesta de tesis doctoral, la cual busca abordar el problema de la hiperparametrización de redes neuronales recurrentes mediante la neuroevolución profunda.

Más allá de los resultados concretos de este trabajo, una tesis doctoral y los artefactos relacionados, creemos que la consecución de los mismos permitirá formar un investigador de alta calidad. Este macro resultado puede ser revisado desde tres ámbitos diferentes: personal, científico e industrial.

En el ámbito **personal** se espera desarrollar las habilidades necesarias para comprender de manera sistemática un campo de estudio, así como también desarrollar la capacidad de realizar una investigación de calidad en dicho campo. De forma puntual se espera validar estas habilidades mediante el aprendizaje de los campos relativos a la tesis doctoral. Asimismo se espera desarrollar la habilidad de analizar críticamente, evaluar y sintetizar nuevas y complejas ideas. También se espera impulsar la capacidad de integración en equipos

multidisciplinares y multiculturales, mediante el trabajo cotidiano en el entorno del grupo de investigación y fomentando la estancia en centros externos.

Por otra parte, se espera que al finalizar el periodo de formación se habrá desarrollado la habilidad de comunicación con la comunidad académica y científica, y con la sociedad en general. Lo cual será indispensable para una correcta difusión de los resultados obtenidos en este trabajo.

En términos generales se espera formar un investigador que sea capaz de aportar a la sociedad mediante el uso de sus habilidades y conocimientos para la resolución de problemas, lo cual sin lugar a dudas tiene un impacto positivo.

En el ámbito **científico** se espera contribuir al estado del arte, lo cual se validará a través de la consecución de publicaciones de calidad.

Finalmente, en el ámbito **industrial** se espera contribuir a solucionar problemas en el contexto de la ciudad inteligente idealmente se espera canalizar estos aportes a través de la transferencia tecnológica a empresas que enfrenten dichos problemas o mediante la creación de un producto comercial. Si bien este punto es de suma complejidad, lograr aportar en él impactaría de forma positiva a la economía, y lo que es más importante, podría significar un aporte a nuestras ciudades.

#### REFERENCIAS

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [2] V. K. Ojha, A. Abraham, and V. Snášel, "Metaheuristic design of feedforward neural networks: A review of two decades of research," *Engineering Applications of Artificial Intelligence*, vol. 60, no. January, pp. 97–116, 2017.
- [3] A. Camero, J. Toutouh, and E. Alba, "Comparing deep recurrent networks based on the mae random sampling, a first approach," in *Conference of the Spanish Association for Artificial Intelligence (CAEPIA) 2018*. Springer, 2018, pp. 1–10.
- [4] R. Miikkulainen, J. Liang, E. Meyerson, A. Rawal, D. Fink, O. Francon, B. Raju, H. Shahrzad, A. Navruzyan, N. Duffy, and B. Hodjat, "Evolving Deep Neural Networks," *arXiv preprint arXiv:1703.00548*, 2017. [Online]. Available: <http://arxiv.org/abs/1703.00548>
- [5] F. P. Such, V. Madhavan, E. Conti, J. Lehman, K. O. Stanley, and J. Clune, "Deep Neuroevolution: Genetic Algorithms Are a Competitive Alternative for Training Deep Neural Networks for Reinforcement Learning," *arXiv preprint arXiv:1712.06567*, 2017. [Online]. Available: <http://arxiv.org/abs/1712.06567>
- [6] X. Yao, "A review of evolutionary artificial neural networks," *International journal of intelligent systems*, vol. 8, no. 4, pp. 539–567, 1993.
- [7] S. Haykin, *Neural Networks and Learning Machines*, 2008, vol. 3.
- [8] M. A. Arbib, *The metaphorical brain 2: Neural networks and beyond*. John Wiley & Sons, Inc., 1989.
- [9] M. W. Dubin, *How the brain works*. John Wiley & Sons, 2013.
- [10] W. S. McCulloch and W. Pitts, "A Logical Calculus of the Idea Immanent in Nervous Activity," *Bulletin of Mathematical Biophysics*, vol. 5, pp. 115–133, 1943.
- [11] S.-i. Amari, "Backpropagation and Stochastic Gradient Descent Method," *Neurocomputing*, vol. 5, no. 4-5, pp. 185–196, 1993.
- [12] Y. LeCun, "Une procédure d'apprentissage pour réseau a seuil asymétrique (a learning scheme for asymmetric threshold networks)," in *Proceedings of Cognitiva 85, Paris, France*, 1985.
- [13] D. Rumelhart, G. E. Hinton, and R. j. Williams, "Learning Internal Representations by Error Propagation," California Univ San Diego La Jolla Inst for Cognitive Science, Tech. Rep. No. ICS-8506, 1985.
- [14] Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle, "Greedy Layer-Wise Training of Deep Networks," *Advances in Neural Information Processing Systems*, vol. 19, no. 1, p. 153, 2007.
- [15] G. E. Hinton, S. Osindero, and Y. W. Teh, "A Fast Learning Algorithm for Deep Belief Nets," *Neural Computation*, vol. 18, no. 7, pp. 1527–1554, 2006.
- [16] G. Bebis and M. Georgiopoulos, "Feed-Forward Neural Networks: Why Network Size is so Important," *IEEE Potentials*, pp. 27–31, 1994.
- [17] A. M. Ukrainec and S. Haykin, "A Modular Neural Network for Enhancement of Cross-Polar Radar Targets," *Neural Networks*, vol. 9, no. 1, pp. 143–167, 1996.
- [18] F. Gruau, L. C. B.-I. I, O. A. D. D. Doctorat, M. J. Demongeot, E. M. M. Cosnard, M. J. Mazoyer, M. P. Peretto, and M. D. Whitley, "Neural Network Synthesis Using Cellular Encoding And The Genetic Algorithm," Ph.D. dissertation, 1994.
- [19] M. Hestenes and E. Stiefel, "Methods of Conjugate Gradients for Solving Linear Systems," *Journal of Research of the National Bureau of Standards*, vol. 49, no. 6, p. 409, 1952.
- [20] Y. Dauphin, R. Pascanu, C. Gulcehre, K. Cho, S. Ganguli, and Y. Bengio, "Identifying and Attacking the Saddle Point Problem in High-Dimensional Non-Convex Optimization," in *Advances in neural information processing systems*, 2014, pp. 2933–2941.
- [21] J. Engel, "Teaching Feed-Forward Neural Networks by Simulated Annealing," *Complex Systems*, vol. 2, pp. 641–648, 1988.
- [22] D. J. Montana and L. Davis, "Training Feedforward Neural Networks Using Genetic Algorithms," *Proceedings of the 11th International Joint Conference on Artificial Intelligence - Volume 1*, vol. 89, pp. 762–767, 1989.
- [23] E. Alba and R. Martí, *Metaheuristic Procedures for Training Neural Networks*. Springer Science & Business Media, 2006, vol. 35.
- [24] D. Whitley, T. Starkweather, and C. Bogart, "Genetic Algorithms and Neural Networks: Optimizing Connections and Connectivity," *Parallel Computing*, vol. 14, no. 3, pp. 347–361, 1990.
- [25] G. Morse and K. O. Stanley, "Simple evolutionary optimization can rival stochastic gradient descent in neural networks," in *Proceedings of the 2016 on Genetic and Evolutionary Computation Conference*. ACM, 2016, pp. 477–484.
- [26] T. B. Luderemir, A. Yamazaki, and C. Zanchettin, "An optimization methodology for neural network weights and architectures," *IEEE Transactions on Neural Networks*, vol. 17, no. 6, pp. 1452–1459, 2006.
- [27] M. T. Mahmoudi, F. Taghiyareh, N. Forouzideh, and C. Lucas, "Evolving Artificial Neural Network Structure Using Grammar Encoding and Colonial Competitive Algorithm," *Neural Computing and Applications*, vol. 22, no. 1, pp. 1–16, 2013.
- [28] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard *et al.*, "Tensorflow: A system for large-scale machine learning," in *OSDI*, vol. 16, 2016, pp. 265–283.
- [29] A. Camero, J. Toutouh, D. H. Stolfi, and E. Alba, "Evolutionary Deep Learning for Car Park Occupancy Prediction in Smart Cities," in *Learning and Intelligent Optimization Conference LION*, 2018.
- [30] A. Camero, J. Toutouh, J. Ferrer, and E. Alba, "Waste generation prediction in smart cities through deep neuroevolution," in *Congreso Iberoamericano de Ciudades Inteligentes (ICSC-CITIES 2018)*, 2018.
- [31] A. Camero, J. Toutouh, and E. Alba, "Low-cost recurrent neural network expected performance evaluation," *arXiv preprint arXiv:1805.07159*, may 2018.
- [32] A. Camero, J. Toutouh, and E. alba, "DLOPT: Deep learning optimization library," *arXiv preprint arXiv:1807.03523*, july 2018.
- [33] A. Camero, G. Luque, Y. Bravo, and E. Alba, "Customer Segmentation Based on the Electricity Demand Signature : The Andalusian Case," *Energies*, vol. 11, no. 7, p. 1788, 2018.
- [34] A. Camero, J. Arellano-Verdejo, and E. Alba, "Road map partitioning for routing by using a micro steady state evolutionary algorithm," *Engineering Applications of Artificial Intelligence*, vol. 71, pp. 155–165, 2018.
- [35] A. Camero, J. Arellano-Verdejo, C. Cintrano, and E. Alba, "Tile map size optimization for real world routing by using differential evolution," in *2017 IEEE Congress on Evolutionary Computation, CEC 2017 - Proceedings*, 2017.
- [36] "EU Commision: Horizon 2020 - The EU Framework Programme for Research and Innovation." <https://ec.europa.eu/programmes/horizon2020>, accessed: 2017-07-12.



# On the Study of Crowdsourced Labeled Data and Annotators: Beyond Noisy Labels

Iker Beñaran-Muñoz<sup>1</sup>

Advisors: Jerónimo Hernández-González<sup>2</sup> and Aritz Pérez<sup>1</sup>

<sup>1</sup> Basque Center for Applied Mathematics, Al. Mazarredo 14, Bilbao, Spain

Emails: {ibenaran, aperez}@bcmath.org

<sup>2</sup> University of the Basque Country UPV/EHU, P. Manuel de Lardizabal 1, Donostia, Spain

Email: jeronimo.hernandez@ehu.eus

## I. INTRODUCTION

In this PhD project, multi-class classification problems are considered. The standard framework is supervised classification: there is a dataset with instances ( $x$ ) that belong each one to only one class  $c$  from a set of possible class labels  $\Omega_C$ , where  $|\Omega_C| > 2$ . The goal is to train a classifier  $\phi$  that is as accurate as possible, based on the instances from a part of the dataset called *training set*. The examples in a training set are hand-labeled by means of expert knowledge. However, due to the rising volume of data and limitations regarding time, expert availability and/or features of the data, other techniques have emerged and their use has become more extended.

Recently, and with the development of new technologies in the information era, the use of crowdsourcing has popularized through multiple web platforms (e.g. Amazon Mechanical Turk or CrowdFlower) that allow to process short tasks by using the workforce of thousands of workers of unknown expertise. In the last years, crowdsourcing has been widely used to solve different kinds of problems, such as text correction [1], text translation [2] or malaria diagnostics [3].

This new paradigm has been welcomed in the machine learning community as a means to collect labels for unlabeled instances in a fast way and at a low cost. In the machine learning context, the workers are referred to as *annotators* or *labelers*. *Crowd labeling* is the process of getting noisy labels for the instances in the training set from a set of various non-expert annotators  $A$ . In this sense, an annotator  $a \in A$  can be seen as a classifier which provides labels with a certain amount of noise. As the annotators are not guaranteed to be experts, many labels are usually gathered for each example. In the *traditional crowdsourcing scenario*, every annotator is asked to select a *single* label for each instance. This crowd labeling approach is referred to as *full labeling* throughout this document.

*Crowd learning* consists of learning a classifier from a dataset with crowdsourced labels. This learning task could be roughly separated into two stages: (i) label aggregation (to determine the ground truth label of each instance of the training set) and (ii) model inference (to learn a model using the aggregated labels and standard supervised classification techniques). If the collected labels fulfill certain conditions,

crowd learning can be as reliable as learning from a single expert in a traditional supervised classification framework [4], [5].

Most of the approaches to crowd learning, mentioned below, focus on the first stage mentioned above (label aggregation). Probably the most popular label aggregation technique is majority voting (MV), which assigns to each instance the label that most annotators have selected for it. In weighted voting [6], the label selection of each annotator is weighted according to their reliability. As the expertise of the annotators is often unknown, their reliability has to be calculated based on the labels they have provided.

Many aggregation methods that also model the reliability of annotators were derived from the expectation-maximization (EM) strategy [7]. This strategy was first implemented to learn with multiple (expert) annotators by Dawid and Skene [8], and has been widely used since then [9]–[14]. This method computes estimates for the ground truth and at the same time computes maximum likelihood estimates for the parameters that model the reliability of the annotators. It consists of two steps that are iterated until convergence: (i) Expectation (E-step), where the expected values of ground truth values are computed using the current parameter estimates and (ii) Maximization (M-step), where the parameters are updated with the new maximum likelihood estimates given the current expected data. There are some methods [9] that train a classifier throughout this process. In the model inference stage, the most common approach is to use the aggregated labels (which may be a single label or a probability distribution over the class labels for each instance [15], for example) to train a classifier. As can be seen, in the traditional crowd learning scenario, usually only the labels provided by the annotators are used to perform aggregation and model inference, disregarding the explanatory variables. An extensive review of different label aggregation and crowd learning techniques can be found in [16].

## II. HYPOTHESIS

The main hypothesis of this PhD project is that the process of the traditional crowd learning framework can be enhanced if extra relevant information, currently easily accessible but commonly disregarded, is efficiently taken into account. Two

issues of the traditional crowd labeling approach have been identified. This PhD project is aimed to provide a solution to both of them. In the following subsections, each of them is analyzed separately.

1) *Lack of flexibility of the labeling process*: As aforementioned, in full labeling annotators are required to provide a single label. This request may be too strict when an annotator is in doubt between two or more class labels. Forcing them to choose only one label even if they are not sure could lead to wrong answers. The main hypothesis of this research line is that a more flexible approach to crowd labeling can extract more information from the available labelers. In this context, this project will study the *candidate labeling* approach, where annotators are allowed to provide a set of labels  $L$  (called *candidate set*) instead of a single label for each instance. In this way, the correct class label is more likely to be selected and the doubts of each annotator can be reflected.

This first proposal of this PhD project [17], already sent to an international journal for revision, is inspired by the subfield of weak supervision [18], which groups different supervised learning problems where the information of supervision is incomplete. This proposal is especially based on the partial or candidate labels [19] problem, which assumes that all the training examples are provided together with a set of labels, with the guarantee that the real label is in that set. This concept is extended to the context of crowd learning and allows annotators to provide as many labels as they want when they are not sure enough to choose a single one. Note that, unlike in the original candidate labels problem, in this case it is not guaranteed that the real label is in the set provided by an annotator. Frameworks where the single-label request is relaxed have already been proposed, such as the works by [20] and [21], where annotators can say how sure they are about their annotations, or other works where annotators are allowed to claim that they do not know the answer [22], [23]. Our idea may be seen as a step forward in the same direction.

In social sciences, a similar problem has been extensively studied under the name of *approval voting* [24]–[26]. Without ground truth, the objective is to identify popular (approved) options. When a single option needs to be selected, aggregation is usually carried out as follows (using machine learning terminology): Given an instance  $x$ , the label included in most candidate sets is chosen. The studies carried out in this field are not of our interest since there is not an aim of estimating a ground truth or of learning any model. Moreover, the aggregation step disregards the information that the size of the candidate sets can bring: confident labelers will provide fewer labels than the hesitant labelers. Assuming that self-confidence and expertise of the annotators are related, the contribution of each annotator could be weighted by, for example, giving more importance to the candidate sets that contain fewer labels. This idea is addressed in [17] under the name of *candidate voting*.

In [27], they already provided some evidence that workers answer faster using candidate labeling (“checkbox interface”) than using full labeling (“radio button interface”). Our hypothesis is that not only is this method less costly, but that

more knowledge can be extracted and hence better results can be obtained than with full labeling. Novel aggregation and learning methods will be developed within the candidate labeling scenario in order to achieve more efficient learning, in the sense that less time and annotators are required to obtain similar results as techniques using full labeling.

2) *Lack of use of the explanatory variables*: In crowd-sourcing scenarios, the descriptive information of the features of the instances, available by definition in every supervised classification problem, is rarely used to enhance the label aggregation process. The sporadic use of this information is mainly devoted to the estimation of the reliability of the annotators [28] or to model the difficulty of the instances within a framework of active learning [5]. However, the explanatory information only takes part in the decisions of the aggregation functions indirectly. Up to our knowledge, no aggregation technique in the related literature uses explicitly this information.

The hypothesis of this second line of research is that the use of the explanatory features during label aggregation can enhance the performance of these techniques. Indirectly, this could impact on the cost of the labeling task, as a lower number of labels would be required to get a dataset satisfactorily labeled.

In order to deal with this issue, this research line aims to produce aggregation methods that exploit the concept of vicinity to aggregate the ground truth label of an instance in the context of full labeling. This study is based on the intuition that, when the class distribution evolves smoothly with respect to the instance space, the class information included in the neighborhood of an instance can be exploited to estimate its class distribution. Under this smoothness assumption, a lower number of labels for a part of the examples might be necessary to obtain correctly aggregated labels.

As of today, we are studying the combination of both the labels gathered for the instance at hand and the labels collected for its  $k$  nearest neighbors for label aggregation. This idea, named as *k-nearest voting*, can be understood as an extension of the majority voting technique described above that takes into account the features of the instances as well. This method preserves the simplicity of basic strategies such as (weighted) majority voting, and is able to exploit the useful information from the explanatory variables.

### III. OBJECTIVES

The main goal of this PhD project is to develop methods to learn from the crowds using both candidate labeling and information from the features. The idea is to make the aggregation and learning stages more efficient, in the sense that better results are reached without increasing the number of annotators. The objectives are as follows:

- O1** To study the benefits and weaknesses of both (i) the candidate labeling framework and related learning strategies, and (ii) the use of the features of the instances for label aggregation and associate voting schemes.



- O2** To create real-world datasets in order to test the candidate labeling strategy and different aggregation schemes.
- O3** To develop algorithms to learn classifiers from crowd-sourced data with candidate labeling and aggregation schemes that take into account the information of the explanatory features too.
- O4** To apply the novel methods to the real problem of skin cancer diagnosis through medical images throughout a collaboration with physicians and researchers of a local hospital.

#### IV. METHODOLOGY

This PhD project follows the general methodology of studying each problem from a theoretic point of view and then through an empirical analysis. The results obtained with the fulfillment of the objectives will be sent to a journal of the JCR for evaluation (preferably to one of the first quartile). A version with preliminary results might be presented in a conference of the field. The tasks planned for the attainment of the different objectives are detailed below:

**O1:** To study the benefits and weaknesses of both (i) the candidate labeling framework and related learning strategies, and (ii) the use of the features of the instances for label aggregation and associate voting schemes.

Although the objectives are similar for both research lines, the tasks are different and they are explained below for each one of them.

Tasks planned for part (i):

- T1 Literature review focused on crowd learning and weak supervision techniques.
- T2 Comparison between the candidate labeling (candidate labeling) and aggregation ( $k$ -nearest voting) technique and the traditional approaches (full labeling and majority voting, respectively).
- T3 Write a paper that formalizes the candidate labeling framework and compare the results obtained with the new and the traditional techniques under different experimental conditions. *NOTE:* A paper with results about candidate labeling has been sent to the journal *Pattern Recognition Letters*.

Tasks planned for part (ii):

- T1 Literature review focused on crowd learning and techniques that take into account the features of the instances.
- T2 Development of techniques that make use of the explanatory variables (as of today,  $k$ -nearest voting has been considered).
- T3 Comparison between the new aggregation techniques that make use of the explanatory variables and the traditional approaches.
- T4 Write a paper that formalize the new framework and compare the results obtained with the new and the traditional techniques under different experimental conditions. *NOTE:* A paper with preliminary results of the  $k$ -nearest voting has been sent to the conference *CIKM 2018*.

**O2:** To create real-world datasets in order to test the candidate labeling strategy and different aggregation schemes.

- T1 Study the available platforms to obtain annotations (Amazon Mechanical Turk, Crowdflower...).
- T2 Make the necessary adaptations in order that the chosen platform works with candidate labeling.
- T3 Generate datasets that are appropriate to test the proposed techniques associate to candidate labeling against state-of-the-art approaches.
- T4 Publish the newly generated datasets in a journal in order to make them accessible.

**O3:** To develop algorithms to learn classifiers from both (i) crowdsourced data with candidate labeling and (ii) labels aggregated through schemes that take into account the information of the explanatory features.

As in **O1**, the tasks vary from the part (i) to the part (ii) of this objective. The tasks planned for part (i) are as follows:

- T1 Literature review focused on crowd learning techniques, especially the ones related to the EM method.
- T2 Extension of existing methods to the candidate labeling framework and development of novel techniques to learn classifiers within that scenario.
- T3 Write a paper with preliminary results for evaluation at a conference of the area. *NOTE:* A paper with preliminary results of an EM-based method extended to candidate labeling has been approved for presentation at *CAEPIA 2018*.
- T4 Write papers of selected methods developed in T2 for both the candidate labeling and the  $k$ -nearest voting frameworks.

Tasks planned for part (ii):

- T1 Literature review focused on crowd learning techniques and methods that take into account the explanatory variables of the instances.
- T2 Introduction of schemes that take into account explanatory variables into known learning techniques, and/or development of novel techniques to learn classifiers within that framework. Also, combination of these novel techniques (e.g.,  $k$ -nearest voting) and the candidate labeling scenario.
- T3 Write papers of selected methods developed in T2, showing results.

**O4:** To apply the novel methods to the real problem of skin cancer diagnosis through medical images throughout a collaboration with physicians and researchers of a local hospital.

- T1 Obtain (a) dataset(s) of medical images suitable for our approach.
- T2 Literature review focused on image classification and pattern recognition.
- T3 Apply the methods developed in **O3** to the medical images dataset(s).
- T4 Write paper describing the dataset(s) used, the experimentation carried out and the results reached in the previous task.

## V. RELEVANCE

This PhD project opens two novel research lines to work with in the context of crowd learning. One is the candidate labeling framework. Despite having been used previously under the name of approval voting by researchers from the area of social sciences, that kind of labeling has barely received attention in the machine learning community. Thus, many new learning methods may be built (apart from the ones developed in this project) within this framework, and the new datasets that are generated could be used by others to develop those methods. By posing a more relaxed request to the annotators, more information is expected to be exploited and, in consequence, more efficient learning may be possible than with full labeling.

The second research line is the idea of introducing the explanatory variables of the instances into the aggregation stage. The  $k$ -nearest voting, for example, can be combined with different learning models or be inserted as an intermediate step into an aggregation scheme. If the labels collected for a certain instance are combined with those gathered for its neighbors, extra information is exploited in comparison to the traditional crowd learning framework. In situations where there are instances that are not labeled or have few labels, these kind of techniques may be useful.

As mentioned in the objective **O4**, application of the new methods will be carried out in collaboration with reputable researchers from a local hospital. We expect that the results reached have a positive impact in the resolution of the problem of skin cancer diagnosis through medical images and that the new techniques are used in that kind of diagnosis.

## REFERENCES

- [1] M. S. Bernstein, G. Little, R. C. Miller, B. Hartmann, M. S. Ackerman, D. R. Karger, D. Crowell, and K. Panovich, "Soylent: a word processor with a crowd inside," *Communications of the ACM*, vol. 58, no. 8, pp. 85–94, 2015.
- [2] J. Corney, A. Lynn, C. Torres, P. Di Maio, W. Regli, G. Forbes, and L. Tobin, "Towards crowdsourcing translation tasks in library cataloguing, a pilot study," in *Digital Ecosystems and Technologies (DEST), 2010 4th IEEE International Conference on*. IEEE, 2010, pp. 572–577.
- [3] M. A. Luengo-Oroz, A. Arranz, and J. Frean, "Crowdsourcing malaria parasite quantification: an online game for analyzing images of infected thick blood smears," *Journal of medical Internet research*, vol. 14, no. 6, p. e167, 2012.
- [4] R. Snow, B. O'Connor, D. Jurafsky, and A. Y. Ng, "Cheap and fast - but is it good? evaluating non-expert annotations for natural language tasks," in *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2008, pp. 254–263.
- [5] V. S. Sheng, F. J. Provost, and P. G. Ipeirotis, "Get another label? improving data quality and data mining using multiple, noisy labelers," in *Proceedings of the 14th ACM International Conference on Knowledge Discovery and Data Mining (SIGKDD)*, 2008, pp. 614–622.
- [6] D. R. Karger, S. Oh, and D. Shah, "Iterative learning for reliable crowdsourcing systems," in *NIPS*, 2011, pp. 1953–1961.
- [7] A. P. Dempster, N. M. Laird, and D. B. Rubin, "Maximum likelihood from incomplete data via the EM algorithm," *J. Royal Stat. Soc. Series B*, vol. 39, no. 1, pp. 1–38, 1977.
- [8] A. P. Dawid and A. M. Skene, "Maximum likelihood estimation of observer error-rates using the EM algorithm," *J. Royal Stat. Soc. Series C*, vol. 28, no. 1, pp. 20–28, 1979.
- [9] V. C. Raykar, S. Yu, L. H. Zhao, G. H. Valadez, C. Florin, L. Bogoni, and L. Moy, "Learning from crowds," *J Mach Learn Res*, vol. 11, pp. 1297–1322, 2010.
- [10] P. Welinder, S. Branson, S. Belongie, and P. Perona, "The multidimensional wisdom of crowds," in *Proc of NIPS 23*, 2010, pp. 2424–2432.
- [11] E. Côme, L. Oukhellou, T. Denoeux, and P. Akinin, "Learning from partially supervised data using mixture models and belief functions," *Pattern recognition*, vol. 42, no. 3, pp. 334–348, 2009.
- [12] J. Whitehill, P. Ruvolo, T. Wu, J. Bergsma, and J. R. Movellan, "Whose vote should count more: Optimal integration of labels from labelers of unknown expertise," in *Proc. of NIPS 22*, 2009, pp. 2035–2043.
- [13] P. L. López-Cruz, C. Bielza, and P. Larrañaga, "Learning conditional linear gaussian classifiers with probabilistic class labels," in *Conference of the Spanish Association for Artificial Intelligence*. Springer, 2013, pp. 139–148.
- [14] Y. Zhang, X. Chen, D. Zhou, and M. I. Jordan, "Spectral methods meet em: A provably optimal algorithm for crowdsourcing," in *Advances in neural information processing systems*, 2014, pp. 1260–1268.
- [15] R. Jin and Z. Ghahramani, "Learning with multiple labels," in *Proceedings of Advances in Neural Information Processing Systems 15 (NIPS)*, 2002, pp. 897–904.
- [16] J. Zhang, V. S. Sheng, J. Wu, and X. Wu, "Multi-class ground truth inference in crowdsourcing with clustering," *IEEE Trans. Knowl. Data Eng.*, vol. 28, no. 4, pp. 1080–1085, 2016.
- [17] I. Beñaran-Muñoz, J. Hernández-González, and A. Pérez, "Weak Labeling for Crowd Learning," *ArXiv e-prints*, 2018.
- [18] J. Hernández-González, I. Inza, and J. A. Lozano, "Weak supervision and other non-standard classification problems: A taxonomy," *Pattern Rec. Lett.*, vol. 69, pp. 49–55, 2016.
- [19] T. Cour, B. Sapp, and B. Taskar, "Learning from partial labels," *Journal of Machine Learning Research*, vol. 12, pp. 1501–1536, 2011.
- [20] C. Grady and M. Lease, "Crowdsourcing document relevance assessment with mechanical turk," in *NAACL HLT 2010 workshop*, 2010, pp. 172–179.
- [21] P. Smyth, U. M. Fayyad, M. C. Burl, P. Perona, and P. Baldi, "Inferring ground truth from subjective labelling of venus images," in *Proc of NIPS 7*, 1994, pp. 1085–1092.
- [22] J. Zhong, K. Tang, and Z.-H. Zhou, "Active learning from crowds with unsure option," in *Proc. of 24th IJCAI*, 2015, pp. 1061–1068.
- [23] M. Venzani, J. Guiver, P. Kohli, and N. R. Jennings, "Time-sensitive bayesian information aggregation for crowdsourcing systems," *J. Artif. Intell. Res.*, vol. 56, pp. 517–545, 2016.
- [24] S. J. Brams and P. C. Fishburn, "Approval voting," *Am. Polit. Sci. Rev.*, vol. 72, no. 3, pp. 831–847, 1978.
- [25] J.-C. Falmagne and M. Regenwetter, "A random utility model for approval voting," *J. Math. Psychol.*, vol. 40, no. 2, pp. 152–159, 1996.
- [26] A. D. Procaccia and N. Shah, "Is approval voting optimal given approval votes?" in *NIPS*, 2015, pp. 1801–1809.
- [27] S. O. A. Banerjee and D. Gurari, "Let's agree to disagree: A meta-analysis of disagreement among crowdworkers during visual question answering," in *GroupSight Workshop at AAAI HCOMP*, Quebec City, Canada, 2017.
- [28] Y. e. a. Yan, "Modeling annotator expertise: Learning when everybody knows a bit of something," in *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS)*, 2010, pp. 932–939.

---

# Doctoral Consortium

## SESIÓN 2





# AN STUDY OF THE INFLUENCE OF FUZZY VARIABLES ON THE ECONOMIC ANALYSIS

Javier Bonilla  
Facultad de Ciencias  
Matemáticas  
Universidad Complutense de  
Madrid  
Madrid, Spain  
[javierlb@ucm.es](mailto:javierlb@ucm.es)  
Started October 2015

Javier Montero  
Facultad de Ciencias  
Matemáticas  
Universidad Complutense de  
Madrid  
Madrid, Spain  
[monty@mat.ucm.es](mailto:monty@mat.ucm.es)

J. Tinguaro Rodríguez  
Facultad de Ciencias  
Matemáticas  
Universidad Complutense de  
Madrid  
Madrid, Spain  
[jtrodrig@mat.ucm.es](mailto:jtrodrig@mat.ucm.es)

**Abstract**— Predicting Gross Domestic Product is very important because until the final data is available, either temporarily or permanently, several weeks get spend after the quarter ends. So, we propose a new estimation based on text mining in economics documents based on a new proposed fuzzy clustering method with a new objective function.

**Keywords**—fuzzy logic; fuzzy clustering; intuitionistics fuzzy sets; fuzzy entropy; intuitionistic fuzzy generator; paired fuzzy sets; text mining; Gross Domestic Product estimation.

## I. Resume

### A. Description

Fuzzy logic enables to assign a membership degree between zero and one to each object to indicate the degree up to which that object belongs to a cluster, as introduced in [30]. After several decades, the work in [1] introduced an extension of fuzzy sets called intuitionistic fuzzy sets, which allow to also measure the non-membership degree and hesitation degree of an object with respect to a cluster, in order to try to find a better classification of reality. More information about different types of fuzzy sets can be find at [2] or [15].

Fuzzy models based on Belnap's logic further extends the intuitionistic model, so that the hesitation degree is divided in two fuzzy set, one is a degree of ignorance or lack of information and the second fuzzy set is contradiction, ambiguity or excess of information [11,17]. Moreover, in [16] and [20] the hesitation degree was divided in three fuzzy sets, indeterminacy, ambivalence and conflict, under the paired fuzzy sets approach. Other example of fuzzy model is the picture fuzzy sets [25] where a new fuzzy set appears, the refusal

degree, which is different from the neutral degree which is in turn more or less similar to the hesitation degree.

Text mining started in the sixties of last century with the work in [23] aimed to create the computer program General Inquirer<sup>1</sup>, which had the ability to extract information from data text using contextual analysis or programming natural language, with the use of dictionaries to classification of works. Other relevant papers about this topic are: [4,19] and [28].

Predicting Gross Domestic Product (GDP) is very important because until the final data is available, either temporarily or permanently, several weeks get spend after the quarter ends. So, different statistical methods as time series, confidence indicators or other economic variables can be used to predict the evolution of GDP. In order to apply the previous developments, we analyzed a data set consisting of the speeches of the president of the US Federal Reserve to build a new confidence index for predicting the quarterly evolution of US GDP. Examples for others authors with others statistical methods such as time series can be found in [7,10,12,13,21,22].

### B. General objectives

The general objective of this study is: To develop a new objective function and a new method of fuzzy clustering based on paired fuzzy sets [16] or intuitionistics fuzzy sets [1], with the application of the interactive descendent gradient method as the Fuzzy C-means Method [3,9]. The aim is enabling the classification of economic texts in order to create an advanced estimator of GDP.

---

<sup>1</sup> <http://www.wjh.harvard.edu/~inquier/>

### C. Specific objectives

The specific objectives we pursue are the following:

The development of the new mathematical methods for fuzzy clustering in order to classify data sets in clusters providing a better resume of information [5].

The estimation of some parameters of the models studied in [5], with the idea of not having to search a value for each of them with a grid or others methods such us genetic algorithms or particle swarm optimization.

The skills to extract information from text data sets [19], with the idea of splitting the text data sets on subjects or topics [28].

The comparison of the new methods developed with existing methods in the literature [3,8,14] and [25].

An application of the new methods is the classification of economics texts in order to create an advanced estimation of GDP.

### II. Methodology in the research plan

The methodology to be applied is based on the development of new fuzzy methods through the modification of the objective function of Fuzzy C-Means to allow the use of Tsallis entropy [27], and introducing a new parameter to link the entropy and tolerance of the model, as well as the application of intuitionistic fuzzy sets as part of the models or as a refinement of the solution.

We develop the estimation of the parameters of some negation fuzzy complement of Yager [29] and Sugeno [24], in order to generate fuzzy intuitionistic sets [6,18,26]. For example, the mode is used as part of the new estimators.

We compare the new methods with Fuzzy C-Means [3,9] and K-means [14] methods, with statistically significant differences between the new methods versus old methods. So we obtained better results on classification with the proposed methods.

These three first ideas appeared in the authors' work [5], containing proofs of the properties of both the new methods and the estimators of parameters.

To extract the information from text we change the way how to do it, in order to lemmatizer [4] versus stemmer the words [28], with the idea to get better results. Other important points [28] on this process are the tokenification of text, elimination

of stopwords and the use of term frequency and the inverse document frequency (tf-idf) metric. In [5] we used eight text dataset from [28].

About the application on GDP estimation, we use the speeches of the President of the US Federal Reserve, specifically Ben S. Bernanke and Alan Greenspan. The first has been president since 2006 to 2014 and the second from 1987 to 2006. Thus, we create the dataset speeches from the speeches of the President of US Federal Reserve (discarding the testimony or statements). To generate this dataset we use the General Inquirer program, as shown in [5].

### III. Relevancy

The main relevancy of this research is linked to the development of new methods of unsupervised classification, with the main idea of obtaining better partitions than those the previous methods offered. From a scientific point of view, we develop advances on the understanding of the behavior of objective functions and parameter settings.

The proposed methods can be applied to several fields, for example in economic analysis, social networks analysis, engineering, biostatistics or statistics.

A specific application of this research is in the estimation of GDP, a quite relevant issue in most economic processes, and thus in their associated decision making.

### References

- [1] K. T. Anatasov, "Intuitionistic Fuzzy Sets", In *Fuzzy Sets and Systems* 20, Elsevier, 1986, pp. 87-96.
- [2] B. Bede, "Mathematics of Fuzzy Sets and Fuzzy Logic", Berlin: Springer, 2013.
- [3] J. C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms", New York: Plenum Press, 1981.
- [4] S. Bird, E. Klein and E. Loper, "Natural language processing with Python", O'Reilly Media Inc., 2009.
- [5] J. Bonilla, J. Montero, J. T. Rodriguez and D. Velez, "New fuzzy non-suervised methods with applications to text mining", unpublished.
- [6] H. Bustince, J. Kacprzyk and V. Mohedano, "Intuitionistic fuzzy generators: Application to intuitionistic fuzzy complementation", *Fuzzy Sets and Systems*, num. 114, Elsevier, 2000, pp. 485-504.
- [7] J. L. Cendajas Bueno, S. de Lucas Santos and M. J. Delgado Rodríguez, "Evaluación del cambio estructural en los indicadores cíclicos", *Estadística Española*, Vol. 56, Num. 183, 2014 , pp. 39-59.

- [8] T. Chaira, "A novel intuitionistic fuzzy C means clustering algorithm and its application to medical images", *Applied Soft Computing*, num. 11, Elsevier, 2011, pp. 1711–1717.
- [9] J. C. Dunn, "A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters". *Cybernetics and Systems*, num. 3, vol. 3, IEEE, 1973, pp. 32-57.
- [10] M. Forni, M. Hallin, M. Lippi and L. Reichlin, "Coincident and leading indicators for the euro area", *The Economic Journal*, Vol. 111, Num. 471, Conference Papers, pp. 62-85, May 2001.
- [11] C. Franco, J. Montero and J. T. Rodríguez, "Relational structures for measures of ignorance", *EUSFLAT-LFA 2011*, Atlantis Press, July 2011.
- [12] M. Gallardo and M. Pedersen, "Resumen de metodologías de referencia para construir un indicador regional en América latina", *Estudios Estadísticos y Prospectivos*, 2007, pp. 1-59.
- [13] G. Gamba-Méndez, G. Kapetanios and R. J. Smith, "An Automatic Leading Indicator of Economic Activity: Forecasting GDP growth for European Countries", 1999, pp. 1-30.
- [14] J. B. MacQueen, "Some Methods of Classifications and Analysis of Multivariate Observations", *Proc. of 5th Berkeley Symposium on Math, Stat. and Prob.*, 1967, pp. 281-297.
- [15] J. Montero, D. Gómez and H. Bustince, "On the relevance of some families of fuzzy sets", *Fuzzy Sets and Systems*, Elsevier, Num. 158, 2007, pp. 2429-2442.
- [16] J. Montero, H. Bustince, C. Franco, J. T. Rodríguez, D. Gómez, M. Pagola, J. Fernández and E. Barrenechea, "Paried structures in knowledge representation", *Knowledge-Based Systems*, Elsevier, 2016.
- [17] M. Öztürk and A. Tsoukiás, "Modelling uncertain positive and negative reasons in decision aiding", *Decision Support Systems*, Num. 43, 2007, pp. 1512-1526.
- [18] N. R. Pal, H. Bustince, M. Pagola, U. K. Mukherjee, D. P. Goswami and G. Beliakov, "Uncertainties with Atanassov's Intuitionistic Fuzzy Sets: Fuzziness and Lack of Knowledge". *Information Sciences*, num. 228, Elsevier, 2013, pp. 61-74.
- [19] J. Pueyo and J. Quiles-Follana, "Trends in Natural Language Processing and Text Mining", *The European Journal for informatics Professional Upgrade*, Vol. XI, issue No. 3, pp. 33-39, June 2010.
- [20] J. T. Rodríguez, C. Franco, D. Gómez and J. Montero, "Paried structures and other opposites-based models", *16<sup>th</sup> IFSA and 9<sup>th</sup> EUSFLAT*, Atlantis Press, 2015.
- [21] D. Romer, "Advanced Macroeconomics", 3th edition, McGraw-Hill Companies, Inc. 2006.
- [22] J. H. Stock and M. W. Watson, "A probability model of the coincident economic indicators", *Nber working paper series*, num. 2772, 1988, pp. 1-41.
- [23] P. J. Stone, D. C. Dumphy, M. S. Smith and D. Ogilvie, "The General Inquirer: a computer approach to content analysis". Cambridge, MA: MIT Press, 1966.
- [24] M. Sugeno, "Fuzzy measures and fuzzy integrals: a survey", *Fuzzy Automata and Decision Process*, M. Gupta, G. N. Saridis, and B. R. Gaines, Eds., North Holland, 1977, pp. 82-102.
- [25] P. H. Thong and L. H. Son, "Picture fuzzy clustering: a new computational intelligence method", *Soft Comput Methodologies and Application*, num. 20, vol. 9, Springer, 2016, pp. 3549–3562.
- [26] E. Trillas, "On negation functions in fuzzy set theory", S. Barro, A. Bugarin, and A. Sobrino, Eds., "Advances in Fuzzy Logic", Universidade de Santiago de Compostela, 1998, pp. 31-43.
- [27] C. Tsallis, "Possible generalization of Boltzmann-Gibbs statistics", *Journal of Statistical Physics*, num. 52, vol. 1-2, 1988, pp. 479-478.
- [28] D. Velez, J. Sueiras, A. Ortega, and J. F. Velez, "A method for K-means seeds generation applied to text mining", *Statistical Methods and Applications*, num. 25, vol. 3, Springer, 2016, pp. 477-499.
- [29] R. R. Yager, "On the measures of fuzziness and negation. Part II: lattices", *Information and Control*, num. 44, 1980, pp. 236-260.
- [30] L. A. Zadeh, "Fuzzy Sets", *Inf. Control*, Num. 8, Vol. 3, 1965, pp. 338-353.

# Modelos descriptivos basados en aprendizaje supervisado para el tratamiento de grandes volúmenes de datos y flujos continuos de datos

Doctorando: Ángel Miguel García Vico

Directores: Pedro González García y Cristóbal José Carmona del Jesus  
Grupo de Investigación “Sistemas Inteligentes y Minería de Datos” (SiMiDat)

*Departamento de Informática*  
*Universidad de Jaén, Jaén, España*  
agvico@ujaen.es

***Index Terms***—Descubrimiento de reglas descriptivas supervisadas, minería de patrones emergentes, algoritmos evolutivos multi-objetivo, sistemas difusos evolutivos.

## I. INTRODUCCIÓN

La minería de datos se ha dividido fundamentalmente en dos enfoques: predictivo, cuyo objetivo es la predicción del valor de una variable de interés en nuevas instancias no vistas anteriormente, utilizando para ello aprendizaje supervisado; y descriptivo con el objetivo de encontrar y definir relaciones interesantes en los datos utilizando para ello aprendizaje no supervisado. No obstante, a lo largo de la literatura se han ido desarrollando técnicas que se encuentran a medio camino entre ambos enfoques, agrupadas en el marco denominado “descubrimiento de reglas descriptivas basadas en aprendizaje supervisado” (SDRD) [1], [2] cuyo propósito es la descripción de conocimiento relevante sobre la variable de interés en un conjunto de datos. Dentro del SDRD, las técnicas más destacadas son el descubrimiento de subgrupos (SD) [3], [4], la minería de patrones emergentes (EPM) [5], [6] y la minería de conjuntos de contraste (CSM) [7].

El principal objetivo de las técnicas SDRD no es la extracción de un modelo con el fin de clasificar nuevas instancias, sino la obtención de un modelo que permita describir de una manera simple y fácilmente comprensible el fenómeno subyacente en los datos por parte de los expertos. En concreto, el objetivo de SD se define como la extracción de reglas cuya distribución estadística sea inusual respecto a una clase de interés. En CSM el objetivo principal es la búsqueda de reglas que definen conjuntos de una población con amplias diferencias de soporte entre grupos del conjuntos de datos. Por último, EPM tiene como objetivo la extracción de reglas respecto a una variable objetivo cuyo soporte sea muy alto en la clase de interés o muy bajo o nulo para el resto, con el objetivo de buscar tendencias emergentes a lo largo del tiempo.

Actualmente vivimos en la era de la información. El desarrollo en las tecnologías de la información y la comunicación ha permitido un aumento exponencial en la cantidad dispositivos generadores de datos, debido principalmente al

abaratamiento de los sistemas de almacenamiento y sensores generadores de datos [8]. Toda esta cantidad de datos contiene conocimiento muy relevante para las empresas para poder mejorar sus servicios [9]. Esto ha propiciado en los últimos años el desarrollo de técnicas de extracción de conocimiento en estos enormes volúmenes de información heterogénea, comúnmente conocido como *Big Data*. El *Big Data* no solo se ve influenciado por el volumen de los datos, sino también por su expansión en otras dimensiones como la variedad y la velocidad [10]. Para hacer frente a este tipo de problemas, se han diseñado diferentes herramientas [11], entre la que destaca el sistema de procesamiento *MapReduce*, así como su implementación de código abierto *Hadoop* [12] o *Spark* [13] para algoritmos iterativos, los cuales son un sistema de computación distribuida basado en dos funciones principales: *Map* y *Reduce* que deben ser diseñadas por los usuarios. A lo largo de la literatura científica, se han desarrollado un amplio conjunto de técnicas para el tratamiento de *Big Data* desde una gran variedad de enfoques.

El desarrollo de dispositivos de generación y transmisión de datos de forma continua como redes de sensores, *smartphones*, dispositivos *wearables*, sistemas de vigilancia, aplicaciones web, banca online, proveedores de energía, etc. [14], han incrementado enormemente la cantidad de flujos continuos de datos existentes. En estos ámbitos, los datos muy antiguos son completamente irrelevantes e incluso contraproducentes en un análisis. En este caso, un análisis continuo de la información conforme los datos lleguen al sistema es más interesante que un análisis tradicional con un gran conjunto de datos históricos. Un flujo de datos se define como un conjunto de instancias potencialmente infinito que llega al sistema a lo largo del tiempo a una velocidad que puede ser variable [15]. Para la extracción de conocimiento en flujos de datos hay que tener en cuenta varios factores que hacen que su extracción sea un desafío en comparación con la minería de datos tradicional. En concreto, se necesita de la actualización continua del modelo de aprendizaje, así como de estrategias para desechar información antigua debido a que no se puede almacenar todo el flujo en memoria [16], [15]. Además, muchos sensores y



fuentes de datos poseen una tasa de refresco muy elevada (del orden de Khz) que implican además un aprendizaje lo más rápido posible [17].

## II. HIPÓTESIS DE PARTIDA

Desde el punto de vista de SDRD, la extracción de conocimiento relativa a la descripción de los datos y, en particular, de la extracción de conocimiento relativa al fenómeno subyacente que los produce es de vital importancia en diferentes ámbitos profesionales como por ejemplo en medicina o bioinformática. En concreto, en los últimos años, SD ha recibido una especial atención dentro de la comunidad científica [18], [19], [20] con propuestas basadas en enfoques clásicos [21], [22], [23] y en sistemas difusos evolutivos [24], [25], [26], [27]. Por su parte, en EPM se han desarrollado un amplio número de algoritmos [28], [29], [30], [31]. Sin embargo, a pesar de la relevancia de la tarea dentro de SDRD, la mayoría de ellos no han tenido en cuenta el balance interpretabilidad/calidad de los resultados obtenidos, ya que han sido utilizados únicamente para clasificación.

Tal y como se ha comentado anteriormente, este tipo de extracción de conocimiento es aún más interesante en entornos Big Data pues la gran cantidad de información existente y la heterogeneidad de las fuentes permite que estos problemas muy complejos sean más fáciles de comprender por parte de los expertos. Sin embargo, al inicio de este trabajo de investigación, solo se había presentado en la literatura especializada un algoritmo para SD enfocado en la extracción de conocimiento en entornos Big Data: el algoritmo MEFASD-BD [32] y no existía ningún método para EPM en este ámbito.

Por otro lado, este conocimiento es muy importante en minería de flujo de datos para una rápida determinación de las causas que producen el flujo y así poder actuar en consecuencia. Sin embargo, aún no se han planteado dentro de la comunidad investigadora propuestas que aprovechen el potencial que tiene SDRD, y en concreto EPM, para la extracción de tendencias emergentes.

Partiendo de estos antecedentes, surge la necesidad de desarrollar técnicas de EPM enfocadas en los objetivos de SDRD, apoyadas a su vez por las propuestas presentadas para SD, para la extracción no solo de patrones altamente discriminativos, sino que además sean fácilmente interpretables, precisos y generales, y con una distribución estadísticamente inusual con respecto a la clase analizada. Asimismo, se hace indispensable que a su vez sean fácilmente escalables para poder ser utilizadas en ámbitos Big Data y/o utilizables dentro de ámbitos de minería de flujos de datos con el fin de obtener conocimiento fácilmente comprensible por los expertos tanto en conjuntos de datos pequeños, como en conjuntos de datos de mayor tamaño y en flujos continuos de datos.

Tras todos estos antecedentes, se establecen las siguientes hipótesis de partida:

- Las técnicas encontradas en la literatura para EPM están claramente enfocadas a predicción, por lo que se pierden muchas de sus capacidades descriptivas. Asimismo, no son lo suficientemente escalables para abordar problemas

de gran dimensionalidad y muchas de ellas por su diseño son incapaces de afrontar la tarea de minería de flujo de datos.

- Con un diseño adecuado, se pueden obtener métodos de extracción de patrones emergentes que permitan la extracción de conocimiento discriminativo, interpretable, preciso y general sobre una distribución de ejemplos estadísticamente inusual respecto a una clase objetivo.
- Con un diseño escalable, se puede mantener un tiempo de procesamiento estable frente al aumento del tamaño del conjunto de datos o a la llegada continua de datos al sistema.
- La extracción de este tipo de conocimiento en bases de datos con alta dimensionalidad o en minería de flujo de datos permitirá cubrir las necesidades de conocimiento que demandan los expertos en este tipo de entornos.
- Los problemas que no eran abordables o impracticables en el pasado, debido a un gran volumen de datos o a una llegada continua de los mismos podrán ser procesados gracias a las nuevas técnicas distribuidas y de minería de flujo de datos.

## III. OBJETIVOS

En base a las hipótesis de partida iniciales, se plantea como objetivo principal de esta tesis el desarrollo de algoritmos de SDRD enfocados a la extracción de conocimiento fácilmente comprensible por el experto dentro de problemas de procesamiento de datos de gran magnitud (*Big Data*) o en problemas de minería de flujos de datos. Este objetivo principal se desglosa en los siguientes subobjetivos:

- 1) Estudio e identificación de los principales enfoques utilizados en SDRD para problemas complejos.
- 2) Desarrollo de nuevas propuestas algorítmicas para la extracción de modelos SDRD, principalmente basados en patrones emergentes, capaces de extraer conocimiento altamente representativo del conjunto de datos analizado y fácilmente comprensibles por parte de los expertos. Este objetivo se subdivide en:
  - a) Desarrollo de propuestas multiobjetivo para la extracción de patrones emergentes.
  - b) Análisis y desarrollo de métodos de filtrado y post-procesamiento.
- 3) Adaptación de las propuestas anteriores para la extracción de este conocimiento en entornos Big Data bajo el paradigma MapReduce, que se divide a su vez en:
  - a) Estudio de los principales enfoques y estrategias utilizadas en sistemas difusos evolutivos para Big Data.
  - b) Desarrollo de propuestas multiobjetivo para extracción de patrones emergentes en entornos Big Data.
  - c) Análisis del equilibrio entre el tiempo y calidad de los resultados obtenidos.
- 4) Adaptación de las propuestas para la extracción de conocimiento altamente descriptivo en entornos de

minería de flujos de datos, que a su vez se divide en los siguientes subobjetivos:

- a) Estudio de los principales enfoques utilizados en minería de flujo de datos.
  - b) Diseño de propuestas multiobjetivo para la extracción de patrones emergentes en flujos continuos de datos.
  - c) Estudio de métodos de visualización de los patrones emergentes extraídos a lo largo del tiempo.
- 5) Aplicación de las propuestas desarrolladas a datos reales con el objetivo de transferir los resultados de investigación al sector productivo y la sociedad en general. En concreto, se pretende aplicar los métodos desarrollados en los siguientes campos:
- a) Energías renovables.
  - b) Gestión de flotas.

#### IV. METODOLOGÍA

El desarrollo de esta tesis implica una metodología de trabajo teórico-práctica pues es necesario por un lado el desarrollo de nuevas metodologías de manera teórica y por otro lado la implementación de las mismas para confirmar su validez. Para la consecución de los objetivos 1,2,3 y 4 así como sus subobjetivos se seguirá el método científico tradicional, el cual se describe a continuación:

- 1) Formulación de hipótesis. Se plantean las hipótesis iniciales de los objetivos a llevar a cabo. En este punto, se diseñarán nuevas propuestas algorítmicas para la extracción de modelos SDRD altamente representativos del conjunto de datos a analizar y fácilmente interpretables por el experto en entornos Big Data y en flujos continuos de datos.
- 2) Recogida de observaciones. Se obtendrán los resultados como consecuencia de la aplicación de los algoritmos desarrollados. En concreto, se utilizarán bases de datos ampliamente conocidas por la comunidad científica del repositorio *UCI Knowledge Discovery in Databases* [33] mediante la utilización de validación cruzada estratificada en conjuntos de datos de gran tamaño. Para flujos continuos de datos, estos se analizarán utilizando la herramienta de análisis de flujos de datos MOA [34], la cual posee generadores de flujos de datos ampliamente conocidos por la comunidad.
- 3) Contraste de hipótesis. Se compararán los resultados obtenidos por los algoritmos desarrollados con el objetivo de analizar su calidad con otras propuestas dentro de la temática. En concreto, para las comparaciones con los algoritmos del estado del arte se trabajará con un *framework* disponible públicamente en el GitHub del grupo de investigación SiMiDat<sup>1</sup> que contiene los algoritmos más relevantes de EPM hasta la fecha. Asimismo, todos los resultados obtenidos serán validados mediante test estadísticos no paramétricos [35].

<sup>1</sup><https://github.com/simidat>

- 4) Demostración o refutación de la hipótesis. La hipótesis se acepta, o se rechaza y se modifica, en función de los resultados obtenidos en las pruebas realizadas.
- 5) Tesis. Extracción, redacción y aceptación de las conclusiones obtenidas durante el proceso.

Para finalizar, el objetivo 5 pretende analizar todos los modelos desarrollados para la extracción de patrones emergentes en distintos problemas de estudio en casos reales. La idea es la extracción de modelos de reglas interpretables bajo aprendizaje supervisado con modelos difusos evolutivos que puedan proporcionar a los expertos de las temáticas a analizar conocimiento de interés.

#### V. PLAN DE TRABAJO

Para poder desarrollar la tesis dentro del período máximo de tres años del programa de doctorado actual, se establece un plan de trabajo en donde se especifica una estimación temporal para la consecución de cada uno de los objetivos propuestos en la sección anterior, así como los diferentes hitos que marcarán el cumplimiento de los mismos. En particular, para cada uno de los subobjetivos propuestos anteriormente se define la siguiente planificación temporal:

- Objetivo 1: Estudio e identificación de los principales enfoques utilizados en SDRD para problemas complejos.
  - Programación: M1-M6.
  - Descripción: Realización de un estudio del estado del arte sobre los algoritmos SDRD, en especial aquellos que usen sistemas difusos evolutivos.
  - Resultados esperados: Informe donde se resuman los enfoques más relevantes de la literatura así como posibles vías de desarrollo de nuevas propuestas para la extracción de modelos SDRD.
- Objetivo 2.a: Desarrollo de propuestas multiobjetivo para la extracción de patrones emergentes.
  - Programación: M6-M15.
  - Descripción: Desarrollo de nuevas propuestas multiobjetivo basadas en sistemas difusos evolutivos para la extracción de patrones emergentes descriptivos.
  - Resultados esperados: Métodos para la extracción de patrones emergentes capaces de mejorar los resultados obtenidos respecto a descripción y carácter diferenciador por los algoritmos presentes en la literatura.
- Objetivo 2.b: Análisis y desarrollo de métodos de filtrado y post-procesamiento.
  - Programación: M10-M15.
  - Descripción: Análisis y estudio de diferentes mecanismos que puedan incorporarse tanto en el proceso evolutivo como en una etapa final para optimizar diversos factores de los métodos evolutivos.
  - Resultados esperados: Obtención de nuevos mecanismos que mejoren los resultados de los algoritmos ya desarrollados.
- Objetivo 3.a: Estudio de los principales enfoques y estrategias utilizadas en sistemas evolutivos para extracción de patrones emergentes en entornos Big Data.



- Programación: M12-M18.
- Descripción: Estudio de la bibliografía especializada en Big Data para el análisis de las estrategias para abordarlo eficientemente.
- Resultados esperados: Obtención de un informe donde se describen las estrategias más relevantes y vías a desarrollar en SDRD.
- Objetivo 3.b: Desarrollo de propuestas multiobjetivo para extracción de patrones emergentes en entornos Big Data.
  - Programación: M15-M24.
  - Descripción: Adaptación de los modelos desarrollados para entornos Big Data.
  - Resultados esperados: Desarrollo de propuestas evolutivas de extracción de patrones emergentes en entornos Big Data capaces de extraer conocimiento en este ámbito.
- Objetivo 3.c: Análisis del equilibrio entre el tiempo y la calidad de los resultados obtenidos.
  - Programación: M20-M24.
  - Descripción: Estudio de la escalabilidad de los métodos implementados para Big Data.
  - Resultados esperados: Obtención de conclusiones que permitan mejorar las implementaciones desarrolladas anteriormente.
- Objetivo 4.a: Estudio de los principales enfoques utilizados en minería de flujo de datos.
  - Programación: M24-M30.
  - Descripción: Estudio de la bibliografía especializada en minería de flujo de datos para el análisis de las estrategias llevadas a cabo para la extracción de conocimiento en este ámbito.
  - Resultados esperados: Obtención de un informe donde se describen las estrategias más relevantes y vías a desarrollar en SDRD.
- Objetivo 4.b: Diseño de propuestas multiobjetivo para la extracción de patrones emergentes en flujos continuos de datos.
  - Programación: M24-M33.
  - Descripción: Adaptación de las propuestas desarrolladas anteriormente a minería de flujo de datos.
  - Resultados esperados: Desarrollo de propuestas evolutivas de extracción de patrones emergentes en entornos de minería de flujos de datos.
- Objetivo 4.c: Estudio de métodos de visualización de los patrones emergentes a lo largo del tiempo.
  - Programación: M28-M33.
  - Descripción: Creación de propuestas para una visualización simple de los patrones emergentes extraídos en entornos de minería de flujo de datos.
  - Resultados esperados: Métodos de visualización que permitan mejorar el análisis a los expertos.
- Objetivo 5.a: Análisis a datos sobre energías renovables.
  - Programación: M30-M36.

- Descripción: Análisis de datos reales sobre sistemas fotovoltaicos de concentración de la Universidad de Jaén que registran datos en tiempo real.
- Resultados esperados: Descubrimiento de posibles anomalías en los equipamientos mediante patrones emergentes en flujos continuos de datos.
- Objetivo 5.b: Análisis a datos de gestión que permitan optimizar el funcionamiento del sistema.
  - Programación: M30-M36.
  - Descripción: Análisis de datos reales de la red de taxis de la ciudad de Nueva York.
  - Resultados esperados: Devolver patrones emergentes a lo largo del tiempo sobre el comportamiento de los usuarios que utilizan el taxi.

Esta planificación temporal se puede observar también en la Figura 1 donde se presenta un cronograma a fin de facilitar la comprensión de la duración de los diferentes objetivos de la tesis a lo largo del tiempo.

## VI. RELEVANCIA

A día de hoy existen tecnologías de aprendizaje automático como por ejemplo el aprendizaje profundo (Deep Learning), entre otros, que permiten la extracción de modelos muy precisos en una gran variedad de problemas. Sin embargo, la gran desventaja de estos modelos es que es prácticamente imposible extraer una conclusión clara de las razones por las que se ha realizado dicha predicción. En este sentido, en ámbitos como la medicina o algunos campos de la industria, economía, entre otros, es de vital importancia la extracción del tipo de conocimiento obtenido mediante técnicas SDRD. En este sentido, la aportación original de esta tesis es la obtención de este tipo de conocimiento simple, fiable y fácilmente interpretable por el experto en conjuntos de datos donde hasta la fecha era impracticable su extracción como en Big Data o en flujos de datos.

A nivel científico, fruto del trabajo desarrollado hasta el momento para esta tesis, se han publicado varias publicaciones en revistas internacionales, entre los que se destacan:

- 1) A. M. García-Vico, F. Charte, P. González, C. J. Carmona, and M. J. del Jesus, “Subgroup discovery with evolutionary fuzzy systems in r: The sdefsr package,” *The R Journal*, vol. 8, no. 2, pp. 307–323, 2016 (Ranking: 52/124 (Q2) en *Statistics & probability*, JCR 2016)
  - En este trabajo se presenta el paquete SDEFSR para el software estadístico R. Dicho paquete contiene los principales algoritmos de descubrimiento de subgrupos basados en sistemas difusos evolutivos.
- 2) J. Luengo, A. M. García-Vico, M. D. Pérez-Godoy, and C. J. Carmona, “The influence of noise on the evolutionary fuzzy systems for subgroup discovery,” *Soft Computing*, vol. 20, pp. 4313–4330, 2016 (Ranking: 33/105 (Q2) en *Computer Science Interdisciplinary Applications*, JCR 2016)
  - En este trabajo se presenta un estudio sobre la influencia del ruido en los algoritmos de descubrim-





como en tiempo de procesamiento a las propuestas presentadas anteriormente. Asimismo, se pretende abrir nuevas líneas de investigación en el campo de SDRD enfocado a regresión.

## REFERENCES

- [1] P. Kralj-Novak, N. Lavrac, and G. I. Webb, "Supervised Descriptive Rule Discovery: A Unifying Survey of Contrast Set, Emerging Pattern and Subgroup Mining," *Journal of Machine Learning Research*, vol. 10, pp. 377–403, 2009.
- [2] C. J. Carmona, M. J. del Jesus, and F. Herrera, "A Unifying Analysis for the Supervised Descriptive Rule Discovery via the Weighted Relative Accuracy," *Knowledge-Based Systems*, vol. 139, pp. 89–100, 2018.
- [3] W. Kloesgen, "Explora: A Multipattern and Multistrategy Discovery Assistant," in *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence, 1996, pp. 249–271.
- [4] S. Wrobel, "An Algorithm for Multi-relational Discovery of Subgroups," in *Proc. of the 1st European Symposium on Principles of Data Mining and Knowledge Discovery*, ser. LNAI, vol. 1263. Springer, 1997, pp. 78–87.
- [5] G. Z. Dong and J. Y. Li, "Efficient Mining of Emerging Patterns: Discovering Trends and Differences," in *Proc. of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM Press, 1999, pp. 43–52.
- [6] A. M. García-Vico, C. J. Carmona, D. Martín, M. García-Borroto, and M. J. del Jesus, "An overview of emerging pattern mining in supervised descriptive rule discovery: Taxonomy, empirical study, trends and prospects," *WIREs: Data Mining and Knowledge Discovery*, vol. 8, no. 1, 2018.
- [7] S. D. Bay and M. J. Pazzani, "Detecting group differences: Mining contrast sets," *Data Mining and Knowledge Discovery*, vol. 5, no. 3, pp. 213–246, 2001.
- [8] A. Fernández, S. Rfo, V. López, A. Bawakid, M. del Jesus, J. Benítez, and F. Herrera, "Big Data with Cloud Computing: An Insight on the Computing Environment, MapReduce and Programming Frameworks," *WIREs Data Mining and Knowledge Discovery*, vol. 5, no. 4, pp. 380–409, 2014.
- [9] X. Wu, X. Zhu, G.-Q. Wu, and W. Ding, "Data mining with big data," *IEEE transactions on knowledge and data engineering*, vol. 26, no. 1, pp. 97–107, 2014.
- [10] T. Kraska, "Finding the Needle in the Big Data Systems Haystack," *IEEE Internet Computing*, vol. 17, no. 1, pp. 84–86, 2013.
- [11] A. Fernández, C. J. Carmona, M. J. del Jesus, and F. Herrera, "A View on Fuzzy Systems for Big Data: Progress and Opportunities," *International Journal of Computational Intelligence Systems*, vol. 9, no. 1, pp. 69–80, 2016.
- [12] T. White, *Hadoop, The Definitive Guide*. O'Reilly Media, Inc., 2012.
- [13] M. Zaharia, M. Chowdhury, M. Franklin, S. Shenker, and I. Stoica, "Spark: Cluster computing with working sets," in *Proceedings of the 2Nd USENIX Conference on Hot Topics in Cloud Computing*, ser. HotCloud'10, 2010, pp. 10–10.
- [14] I. Žliobaitė, M. Pechenizkiy, and J. Gama, "An overview of concept drift applications," in *Big Data Analysis: New Algorithms for a New Society*. Springer, 2016, pp. 91–114.
- [15] J. Gama, *Knowledge discovery from data streams*. CRC Press, 2010.
- [16] A. Bifet, "Adaptive learning and mining for data streams and frequent patterns," Ph.D. dissertation, Universitat Politècnica de Catalunya, 2009.
- [17] D. Han, C. Giraud-Carrier, and S. Li, "Efficient mining of high-speed uncertain data streams," *Applied Intelligence*, vol. 43, no. 4, pp. 773–785, 2015.
- [18] F. Herrera, C. J. Carmona, P. González, and M. J. del Jesus, "An overview on Subgroup Discovery: Foundations and Applications," *Knowledge and Information Systems*, vol. 29, no. 3, pp. 495–525, 2011.
- [19] C. J. Carmona, P. González, M. J. del Jesus, and F. Herrera, "Overview on evolutionary subgroup discovery: analysis of the suitability and potential of the search performed by evolutionary algorithms," *WIREs Data Mining and Knowledge Discovery*, vol. 4, no. 2, pp. 87–103, 2014.
- [20] M. Atzmueller, "Subgroup discovery," *WIREs Data Mining and Knowledge Discovery*, vol. 5, pp. 35–49, 2015.
- [21] M. Atzmueller and F. Puppe, "SD-Map - A Fast Algorithm for Exhaustive Subgroup Discovery," in *Proc. of the 17th European Conference on Machine Learning and 10th European Conference on Principles and Practice of Knowledge Discovery in Databases*, ser. LNCS, vol. 4213. Springer, 2006, pp. 6–17.
- [22] B. Kavsek and N. Lavrac, "APRIORI-SD: Adapting association rule learning to subgroup discovery," *Applied Artificial Intelligence*, vol. 20, pp. 543–583, 2006.
- [23] H. Grosskreutz, S. Rueping, and S. Wrobel, "Tight optimistic estimates for fast subgroup discovery," in *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases*, 2008, pp. 440–456.
- [24] M. J. del Jesus, P. González, F. Herrera, and M. Mesonero, "Evolutionary Fuzzy Rule Induction Process for Subgroup Discovery: A case study in marketing," *IEEE Transactions on Fuzzy Systems*, vol. 15, no. 4, pp. 578–592, 2007.
- [25] M. J. del Jesus, P. González, and F. Herrera, *Fuzzy Sets and Their Extensions: Representation, Aggregation and Models*. Springer, 2007, vol. 220, ch. Subgroup Discovery with Linguistic Rules, pp. 411–430.
- [26] C. J. Carmona, P. González, M. J. del Jesus, and F. Herrera, "NMEEF-SD: Non-dominated Multi-objective Evolutionary algorithm for Extracting Fuzzy rules in Subgroup Discovery," *IEEE Transactions on Fuzzy Systems*, vol. 18, no. 5, pp. 958–970, 2010.
- [27] C. J. Carmona, V. Ruiz-Rodado, M. J. del Jesus, A. Weber, M. Grootveld, P. González, and D. Elizondo, "A fuzzy genetic programming-based algorithm for subgroup discovery and the application to one problem of pathogenesis of acute sore throat conditions in humans," *Information Sciences*, vol. 298, pp. 180–197, 2015.
- [28] J. Bailey, T. Manoukian, and K. Ramamohanarao, "Fast Algorithms for Mining Emerging Patterns," in *Principles of Data Mining and Knowledge Discovery*. Springer, 2002, vol. 2431, pp. 187–208.
- [29] J. Y. Li, G. Z. Dong, K. Ramamohanarao, and L. Wong, "DeEPs: A New Instance-Based Lazy Discovery and Classification System," *Machine Learning*, vol. 54, no. 2, pp. 99–124, 2004.
- [30] H. Fan and K. Ramamohanarao, "Fast discovery and the generalization of strong jumping emerging patterns for building compact and accurate classifiers," *IEEE Transactions on Knowledge and Data Engineering*, vol. 18, no. 6, pp. 721–737, 2006.
- [31] M. García-Borroto, J. Martínez-Trinidad, and J. Carrasco-Ochoa, "Fuzzy emerging patterns for classifying hard domains," *Knowledge and Information Systems*, vol. 28, no. 2, pp. 473–489, 2011.
- [32] F. Pulgar-Rubio, A. J. Rivera-Rivas, M. D. Pérez-Godoy, P. González, C. J. Carmona, and M. J. del Jesus, "MEFASD-BD: Multi-Objective Evolutionary Fuzzy Algorithm for Subgroup Discovery in Big Data Environments - A MapReduce Solution," *Knowledge-Based Systems*, vol. 117, pp. 70–78, 2017.
- [33] D. Dheeru and E. Karra Taniskidou, "UCI machine learning repository," 2017. [Online]. Available: <http://archive.ics.uci.edu/ml>
- [34] A. Bifet, G. Holmes, R. Kirkby, and B. Pfahringer, "MOA: massive online analysis," *Journal of Machine Learning Research*, vol. 11, pp. 1601–1604, 2010. [Online]. Available: <https://moa.cms.waikato.ac.nz/>
- [35] S. García and F. Herrera, "An Extension on "Statistical Comparisons of Classifiers over Multiple Data Sets" for all Pairwise Comparisons," *Journal of Machine Learning Research*, vol. 9, pp. 2677–2694, 2008.
- [36] A. M. García-Vico, F. Charte, P. González, C. J. Carmona, and M. J. del Jesus, "Subgroup discovery with evolutionary fuzzy systems in R: The sdfsfr package," *The R Journal*, vol. 8, no. 2, pp. 307–323, 2016.
- [37] J. Luengo, A. M. García-Vico, M. D. Pérez-Godoy, and C. J. Carmona, "The influence of noise on the evolutionary fuzzy systems for subgroup discovery," *Soft Computing*, vol. 20, pp. 4313–4330, 2016.
- [38] A. M. García-Vico, C. J. Carmona, P. González, and M. J. del Jesus, "Moea-efep: Multi-objective evolutionary algorithm for extracting fuzzy emerging patterns," *IEEE Transactions on Fuzzy Systems*, In Press.
- [39] —, "A big data approach for extracting fuzzy emerging patterns," *Cognitive Computation*, Submitted.
- [40] A. M. García-Vico, J. Montes, J. Aguilera, C. J. Carmona, and M. J. del Jesus, "Analysing Concentrating Photovoltaics Technology through the use of Emerging Pattern Mining," in *Proc. of the 11th International Conference on Soft Computing Models in Industrial and Environmental Applications*. Springer, 2016, pp. 1–8.
- [41] A. M. García-Vico, P. González, C. J. Carmona, and M. J. del Jesus, "Impact of the type of rule in fuzzy emerging pattern mining on a big data approach," in *Proc. of the 2nd International Symposium on Fuzzy and Rough Sets*, 2017, pp. 1–10.
- [42] A. M. García-Vico, P. González, M. J. del Jesus, and C. J. Carmona, "A first approach to handle emerging patterns mining on big data problems: The evaefp-spark algorithm," in *IEEE International Conference on Fuzzy Systems*, 2017, pp. 1–6.

# PhD Thesis proposal:

## A study on the discriminatory capacity of the temporal information on supervised time series classification problems

Amaia Abanda<sup>1,2</sup>

<sup>1</sup> *Basque Center for Applied Mathematics (BCAM)*

<sup>2</sup> *Intelligent Systems Group (ISG)*

*Department of Computer Science and Artificial Intelligence,  
University of the Basque Country UPV/EHU  
Bilbao, Spain  
aabanda@bcmath.org*

Advisors: Usue Mori<sup>2,3</sup>, Jose A. Lozano<sup>1,2</sup>

<sup>3</sup> *Department of Applied Mathematics*

*Statistics and Operational Research  
University of the Basque Country UPV/EHU  
Bilbao, Spain*

Starting date: 1 April 2017

**Abstract**—Time series classification has been always categorized as a particular case of classification in which the input objects are ordered sequences. As such, the research community has assumed that specific methods are required for dealing with this type of data, without really analysing this hypothesis. Specific methods are usually computationally expensive or demand some semantic treatment of the series that may turn the method cumbersome. In this thesis time series classification is addressed from a new point of view: the discriminatory power of the temporal information. In other words, given a dataset, we want to analyse the relevance of the temporal information (the order of the elements of a series, for instance) for classification and explore in which cases the specific methods are necessary and why in depth. Departing from distance based time series classification, the goal of this thesis is to explore which are the temporal characteristic of the time series data in order to measure how relevant they are for classification.

**Index Terms**—time series, classification, temporal information, discriminatory, distance based

### I. INTRODUCTION

Time series data that is constantly being generated in a wide variety of fields such as bioinformatics, financial fields, engineering, etc [1]. Time series represent a particular type of data due the intrinsic temporal nature they have. A time series is an ordered sequence of observations of finite length, observations that are usually taken through time but they may also be ordered with respect to another aspect, such as space

[2]. The large increase in the amount of this kind of data has given rise to an growing interest on studying and mining of time series.

In particular, this thesis is focused on time series classification (TSC), a data mining task which aims at finding a mapping between inputs (time series, in this case) and outputs (class labels o categories) based on some input-output pairs from where the model is learnt. In this manner, the goal of TSC is to predict the class labels of new unlabeled time series.

TSC differs from traditional classification problems in the ordered nature of the input objects. In traditional classification problems, the input objects are feature vector and the order of their attributes is not relevant; any re-ordering of them will produce the same results. In TSC, on the contrary, the input are time series, that is, ordered sequences. In this context, it is generally assumed that the order of the attributes is a discriminatory aspect and that, hence, time series can not be treated as feature vectors. As such, many specific methods for time series haven been proposed over the years.

The methods proposed for TSC can be divided into three main categories [4]: feature based, model based, and distance based methods. In feature based TSC, some representative features of the series are extracted and the series are transformed into feature vectors. Then, any traditional classifier can be employed, since the feature vector is not an ordered input. Some



of the most typical feature based methods are discrete Fourier transform (DFT) [5] or discrete wavelet transform (DWT) [6]. In model based TSC, the main assumption is that the series belonging to the same class are generated by the same underlying model, so the prediction of a new series is done finding the model that best fits it. Some examples include autoregressive models [7][8] or hidden Markov models [9]. Lastly, in distance based time series classification, the classification is done based on the concept of similarity. In this manner, the similarity between two series is defined employing a distance measure; those series that are close to each other respect to a given distance are considered similar, and those which are far away are considered different. It is assumed that series which are similar in some sense, belong to the same class and this similarity concept is measured by using some specific distance measures. Then, this relationship is employed for classifying the new series. This thesis departs from distance based TSC.

Until recently, most of the work done in distance based TSC has focused on defining new distance measures and exploiting them within k-Nearest Neighbour classifiers (in particular, the 1-NN classifier). Different types of similarities focus on different aspects of the time series, such as the shape, the temporal alignment, the correlation or the structure, so the simple approach of 1-NN has achieved a reputation of being difficult to beat [3][11]. However, this competitiveness may come from the strengths of the distance measures more than from the classifier itself [12]. As such, in the past few years many methods have been proposed that include the existing time series distances within more complex classifiers [13] [14] [15].

Time series distance measures can be categorized using many criteria. For instance, a widely employed categorization divides them into lock-step measures and elastic measures. Lock-step measures refer to those distances that compare the  $i$ th point of one series to the  $i$ th point of another (Euclidean distance, for example). Elastic measures, on the contrary, create a non-linear mapping between the series with the purpose of aligning them (Dynamic Time Warping [10], for instance). As such, elastic measures allow a comparison of one point of a series with another point of another series which is not at the same time instant. In other words, lock-step measures do not consider the relationship between an ordered subsequence of a series and another series, while elastic measures do. In this way, if a lock-step distance is employed in a classification task, the series are treated as feature vectors in which the order of the elements is meaningless. By contrast, if an elastic distance is used for classification, the main assumption is that the order of the elements of the series is a relevant aspect for discriminating between classes.

This dichotomy -whether the order of elements of the series is discriminatory or not-, has arisen from distance based TSC but it is, indeed, a more general matter. Most of the methods proposed until now assume that the temporal information of the series is relevant; the methods extract temporal features of the series in order to capture their temporal characteristics, but without really analysing the discriminatory power of these

characteristics. As such, most of the existing approaches for TSC have assumed that, due to their temporal nature, specific methods are required for classifying time series. For instance, in distance based time series classification, this specificity is represented by the methods employing elastic measures.

The main problem with specific methods is that they are usually computationally expensive. In the case of distance based methods, for instance, most of the elastic measures take  $O(n^2)$ , where  $n$  is the length of the longest time series in the database. For large datasets, methods employing this kind of measures become cumbersome and unrealistic for a real application. Generic methods, on the contrary, can be computationally reasonable even for large datasets. In addition, specific methods have often a semantic part that the researchers need to handle; for instance, in feature based method, the researchers should know in advance which temporal features are more discriminatory for the given dataset. As such, the main motivation of this thesis is to understand beforehand in which cases the specific methods are necessary and in which cases a non-specific method would be enough. Hence, the researchers could benefit from this knowledge to save time and effort on TSC. In addition, this novel point of view opens a new direction of research that has never been explored.

In the next sections the objectives of the thesis, the proposed methodology to carry them out, and the relevance of the present thesis are described.

## II. OBJECTIVES

The main objective of this thesis is to establish whether the temporal information of the time series -understood as the main characteristic of this type of data that differentiates it from other type of data- is, or is not, a discriminatory aspect for classification. Departing from distance based TSC, the goal of this thesis is to understand when specific methods are required or not (preferably in advance), and especially, why. This goal can be broken-down into the following sub-objectives:

- 1) **A taxonomy of distance based TSC.** As previously mentioned, many new distance based methods have arisen in the last years, in addition to the classical 1-NN. As such, this sub-objective aims at presenting a taxonomy that integrates all distance based approaches, structuring them in such a manner that the understanding of the field is improved. This sub-objective is in process at the moment and a review on distance based TSC has been recently submitted [2], which includes the proposed taxonomy.
- 2) **Analysis of need of specific methods within distances based TSC to develop a method that decides in advance whether specific methods are needed or not.** The categorization of the methods in specific/non-specific comes easily within distance based TSC by the differentiation of the methods which employ lock-step measures and elastic measures. Lock-step measures treat the series as feature vectors and, thus, are not specific for time series, while elastic measures take

into account the order of the elements of the series and, hence, are specific for time series. In this sub-objective, the temporal information is understood, as a first approximation, as the relevance of the order of the elements. Departing from the lock-step/elastic measures categorization - which no-consider/consider the temporal information, respectively- the main goal is to check if in those cases in which the temporal information is not discriminatory, non-specific methods perform better than specific. In this way, the idea is to develop a methods that decides in advance, for a given dataset, where elastic distance based or lock-step distance based methods will perform better. This sub-objective is in an early stage but some work has been already done in this direction [16].

- 3) **Analysis of need of specific methods in general TSC to develop a method that decides in advance whether specific methods are needed or not.** Following the idea of the previous sub-objective, the goal is to extrapolate the analysis of the specificity of the methods to general TSC. In particular, instead of considering the order as the unique temporal factor, new temporal characteristics will be considered. For instance, in feature based approaches, rather than extracting temporal features (as the amplitude of the series or their Fourier coefficients), we could employ standard feature extraction techniques and compare both approaches in terms of accuracy. At the same time, we could check if there is a correlation between the performance of the specific/non-specific methods in distance based and feature based approaches, to somehow check if the weight of the order in the temporal information. The idea is to understand the intuition about which are the characteristic in a dataset that make the specific (or non-specific) methods more accurate.
- 4) **Proposal of a method that extract the temporal information's discriminatory power for TSC to know in advance which of the existing methods will be more appropriate for a given dataset.** The fourth sub-objective is to give a specific definition of the concept of *temporal information*. This definition will probably be broken-down into different characteristic as the order of the elements of the series or shift between series. The idea is to quantitatively measure, in advance, the power of these characteristics for classification. As such, one could extract these values, the discriminatory power, of each of the defined temporal characteristic for classification from a given dataset and employ them as a kind of weight. Then, the researcher can choose which of the existing method use in coherence with these weights. For instance, if the shift between series turn out to be very discriminative (large weight), a method that takes this fact into account should be used. In particular, most of these temporal weights could be small and that would mean that the temporal information is not relevant

for classification. In this case, the non-specific methods would be probably more appropriate than the specific ones. To summarize, the goal is to develop a method that extract the weight of each temporal characteristic of a given dataset (in the sense how discriminatory they are for classification), in order to choose in advance which kind of method would be more appropriate.

- 5) **Application of the acquired knowledge to solve a real problem.** The goal is to give solutions to real time series classification problems by means of the development of a new method. The specific problem is: given a set of streaming time series with different kind of peaks, classify these peaks into different categories. Hence, it is a sub-series classification in a streaming context. An example of this scenario comes from water distribution companies, in particular, a company called Gipuzkoako Urak S.L. has proposed the following problem: this company has several sensors over a geographic region (Gipuzkoa) which measure the water flows passing through these localizations. These observations are taken over the time (every 5 minutes, for instance) and can be seen as streaming time series. In some specific time instants, there are high water consumptions (time series peaks), which may be caused by several reasons: someone filling the swimming-pool, fire-fighters taking water from a distribution point or water leakages. Since the companies do not differentiate between these peaks, a technician is send to the place every time that the water flow exceeds a established threshold. As such, most of times it is not a water leakage and the technician is sent for nothing. The objective is to propose a method that is able to classify these high water consumptions in the moment that they are happening in order to decide whether it is a water leakage or not (and thus, a technician has to be sent or not). In a general context, this problem can be seen as peak-including-sub-series classification in a streaming scenario.

In the case of the problem proposed by the mentioned company, there is an additional challenge: they do not have the specific label of each peak, i.e., the reason of each high water consumption. Instead, they have some text comments written by the technician that went to check the specific high water consumption. In order to translate the problem to a TSC problem, we should have the specific labels. Hence, another goal within this objective is to apply some labelling technique to the comments in order to obtain a clear ground true of the existing categories.

### III. METHODOLOGY AND WORK PLAN

In this section, a general overview of the proposed methodology is presented. The work plan is defined in order to fulfill each one of the objectives of this thesis. For each objective, the goal is to develop a method (except for the first one: the taxonomy), which will be written and sent to a referred journal



of the JCR. The preliminary findings may also be presented in conferences, preferably international. More concretely, the methodology for each objective is defined as follows:

1) **A taxonomy on distance based TSC:**

- a) A comprehensive revision of the existing distance based TSC methods, with emphasis on those that propose new ways of employing the existing time series distance measures.
- b) Extraction of the characteristics of each method in order to identify the possible categories of methods and explore the different criteria respect to which group the methods.
- c) Proposal of a taxonomy that structures the existing methods in a way that the possible future reader will have a better and more organized understanding of the distance based TSC methods.
- d) Writing of a review on distances based TSC based on the proposed taxonomy and submission to a JRC journal.

2) **Analysis of need of specific methods within distances based TSC to develop a method that decides in advance whether specific methods are needed or not:**

- a) State-of-the-art revision of any method that questions the use of specific methods for TSC, in particular, methods based on distances.
- b) Formulation of the hypothesis regarding the use of specific methods. In particular, a hypothesis that relates the distance based method employing lock-step/elastic (non-specific/specific) measures and general TSC methods that considers/non-considers the temporal nature of the series.
- c) Design of the experimentation and definition of the expected results.
- d) Contrast of the obtained results with the hypothesis to draw conclusions.
- e) Writing of a paper with the obtained conclusions, and submission to an international conference.

3) **Analysis of need of specific methods in general TSC to develop a method that decides in advance whether specific methods are needed or not.:**

- a) Revision of TSC methods in order to check if there are any methods that do not employ specific methods. Analysis of their justifications.
- b) Exploration of the different characteristic of the series (and in general, of the given dataset) that may determine when the specific/non-specific methods would obtain better/worse results and why.
- c) Formulation of the hypothesis about better/worse results in specific/non-specific methods depending on the different characteristic of the datasets.
- d) Definition of the experimentation and specification of the expected results and their correspondence with the formulated hypothesis.
- e) Interpretation of the obtained results and conclusions.

- f) Writing of a paper to present the obtained conclusions and submission to a JRC journal.

4) **Proposal of a method that extract the temporal information's discriminatory power for TSC to know in advance which of the existing methods will be more appropriate for a given dataset:**

- a) Revision of general classification methods which explore the discriminatory power of features obtained from the data. In particular, check if there is any similar work done for time series.
- b) Definition of temporal information and it's possible break-down into different characteristics. Definition of a way to measure the discriminative capacity of these characteristics.
- c) Proposal of a specific framework which, given a dataset, extract the temporal characteristics and the discriminatory power of each of them. Then, depending on the discriminatory power of them, gives a weight to each characteristics and choose the most appropriate method for classifying this dataset. In particular, if the temporal characteristics are found not to be relevant for classification, the proposed framework should choose a non-specific method.
- d) Definition of the experimentation to evaluate the proposed framework.
- e) Writing o a paper to present the developed framework and the analysis that underlies the proposal. Submission to a JRC journal.

5) **Application of the acquired knowledge to solve a real problem.**

- a) Definition of the problem with the help of the representative and the technician of the company Gipuzkoako Urak S.L.. The objective is to understand the structure of the data they have in depth and to define, with their help, the exact problem.
- b) Proposal of a labelling procedure to obtain the class labels of the high water consumptions from the comments of the technicians , as well as an evaluation method for the labelling procedure.
- c) Offline problem: split the time series in the time spans in which there is peack and classify these sub-series with the classes obtained in labelling procedure.
- d) Once the offline scenario is solved, provide a proposal to extrapolate the method to a streaming case.
- e) Presentation of the proposed method to the company to get a feedback.
- f) Writing of a paper with the proposed method and submission to a JRC journal.

#### IV. RELEVANCE

Although the number of ways of employing a time series distance for TSC has increased over the years, a taxonomy

that organizes the field has never been presented, so we think that it would be an important contribution for the researches in the community.

As previously mentioned, in almost every approach of TSC the proposed methods are specific for time series, assuming that the temporal information is a discriminatory aspect for classification. In our opinion, this hypothesis has to be analysed in detail, even if it is the base of practically all the existing approaches. The specific approaches for time series, specially those based on distances, require often high computational cost both for learning and prediction. In addition, depending on the length of the series and the size of the dataset, this methods can become unrealistically expensive in terms of computational time. In those that are not distance based, an specific treatment of the series is usually needed beforehand in order to extract the appropriate features or, in general, to fit an adequate model.

As such, we want to open a new direction of research that has never been explored: first, we want to specify the peculiarities of TSC respect to traditional classification problems from the point of view of the data analysis and, secondly, we want to measure these particular characteristics in terms of their discriminative power. In this manner, these characteristics could me measures in advance to know in order to choose the appropriate method to classify the given dataset. More specifically, these discriminative measures would help to understand whether it is necessary or not the use of specific methods. This progress would help the research community in a great manner by clarifying the relevant features of the time series data for the task of classification.

In addition, the acquired knowledge within this thesis will be applied to a real problem of time series peak classification in a streaming context. It is a innovative and challenging problem that combines different sub-problems of TSC but that has never been addressed specifically. An example where this method could be applied is in water distribution companies. Even if this challenge is a TSC problem, there are rather few works done by the researches in the field, so we think that proposing a comprehensive solution based on a novel methods will also be a innovation to the application domains of the field.

#### ACKNOWLEDGEMENT

This research is supported by the Basque Government through the BERC 2018-2021 program and by Spanish Ministry of Economy and Competitiveness MINECO through BCAM Severo Ochoa excellence accreditation SEV-2013-0323 and through project TIN2017-82626-R funded by (AEI/FEDER, UE) and acronym GECECPAST. In addition, by the Research Groups 2013-2018 (IT-609-13) programs (Basque Government), TIN2016-78365-R (Spanish Ministry of Economy, Industry and Competitiveness). A. Abanda is also supported by the grant BES-2016-076890.

#### REFERENCES

- [1] Eamonn Keogh and Shruti Kasetty. On the need for time series data mining benchmarks. *Proceedings of the 8th ACM SIGKDD*

- International Conference on Knowledge Discovery and Data Mining*, page 102, 2002.
- [2] Amaia Abanda, Usue Mori and Jose A. Lozano. A review on distance based time series classification. *Phhttp://arxiv.org/abs/1806.04509*, 2018.
- [3] Philippe Esling and Carlos Agon. Time-series data mining. *ACM Computing Surveys*, 45(1):1–34, 2012.
- [4] Zhengzheng Xing, Jian Pei, and Eamonn Keogh. A brief survey on sequence classification. *ACM SIGKDD Explorations Newsletter*, 12(1):40, 2010.
- [5] Christos Faloutsos, M. Ranganathan, and Yannis Manolopoulos. Fast subsequence matching in time-series databases. *ACM SIGMOD International Conference on Management of Data*, pages 419–429, 1994.
- [6] I. Popivanov and R. J. Miller. Similarity Search Over Time-Series Data Using Wavelets. *Proceedings 18th International Conference on Data Engineering (ICDE)*, pages 212–221, 2002.
- [7] Anthony Bagnall and Gareth Janacek. A run length transformation for discriminating between auto regressive time series. *Journal of Classification*, 31(October):274–295, 2014.
- [8] Marcella Corduas and Domenico Piccolo. Time series clustering and classification by the autoregressive metric. *Computational Statistics and Data Analysis*, 52(4):1860–1872, 2008.
- [9] Padhraic Smyth. Clustering sequences with hidden Markov models. *Advances in Neural Information Processing Systems*, 9:648–654, 1997.
- [10] Donald Berndt and James Clifford. Using dynamic time warping to find patterns in time series. *Workshop on Knowledge Knowledge Discovery in Databases*, 398:359–370, 1994.
- [11] Xiaopeng Xi, Eamonn Keogh, Christian Shelton, Li Wei, and Chotirat Ann Ratanamahatana. Fast time series classification using numerosity reduction. *Proceedings of the 23rd ICML International Conference on Machine learning*, pages 1033–1040, 2006.
- [12] Pang-Ning Tan, Michael Steinbach, and Vipin Kumar. *Introduction to Data Mining*. Addison-Wesley, Reading, MA, addison-we edition, 2005.
- [13] Rohit J. Kate. Using dynamic time warping distances as features for improved time series classification. *Data Mining and Knowledge Discovery*, 30(2):283–312, 2015.
- [14] Arash Jalalian and Stephan K. Chalup. GDTW-P-SVMs: Variable-length time series analysis using support vector machines. *Neurocomputing*, 99:270–282, 2013.
- [15] Pierre-François Marteau and Sylvie Gibet. On Recursive Edit Distance Kernels With Application to Time Series Classification. *IEEE Transactions on Neural Networks and Learning Systems*, 26(6):1–15, 2014.
- [16] Amaia Abanda, Usue Mori and Jose A. Lozano. Requiere la clasificación de series temporales métodos específicos?. *Submitted*, 2018.

# Banca 3.0: Servicios Inteligentes de valor añadido y Salud Financiera

La Banca privada y personalizada para el cliente ya es posible: sinergia entre Inteligencia Artificial, Analítica de Datos, Big Data y Estadística.

Javier Porras Castaño  
Doctorando, Universidad Rey Juan Carlos I, Madrid  
Inicio en Noviembre de 2017  
Director de Tesis: Carlos Enrique Cuesta Quintero  
Departamento: Ciencias de la Computación  
Ronda, Málaga, España  
@\_javipc  
[www.linkedin.com/in/javipc](http://www.linkedin.com/in/javipc)  
[javiporrascastano@gmail.com](mailto:javiporrascastano@gmail.com)

*Los clientes demandan poder interactuar con su banco al igual que lo hacen con las principales plataformas de Internet. Esta tesis doctoral supondrá una revolución de gran impacto en el sector financiero y cambiará la tradicional relación del cliente con su banco. Éste almacena todos los movimientos financieros que realiza el cliente, lo que supone una cantidad de datos ingente, que en la actualidad no los está utilizando la Banca para generar valor. Gracias a la sinergia entre Inteligencia Artificial, Analítica de Datos, Big Data y Estadística sobre esos datos se podrá ofrecer servicios inteligentes personalizados de valor añadido que modifiquen la relación entre el cliente y su entidad financiera. Esta tesis pretende crear una cuenta inteligente que sea capaz de predecir gastos de consumo (luz, agua, compras, etc) con antelación, ofrecer al cliente un indicador de cómo son sus gastos frente a perfiles similares anonimizados y recomendar productos financieros a medida que mejoren su salud financiera. Además, como innovación disruptiva, el cliente podrá interactuar con estos servicios inteligentes mediante su propia voz porque es la forma más natural e inherente de comunicación del ser humano, con independencia de cómo es su forma de expresión.*

*Predicción, indicadores, recomendación, personalización, voz, innovación, inteligencia, satisfacción y fidelización.*

## I. INTRODUCCIÓN

El sector bancario está experimentando importantes transformaciones que tienen origen en la imparable innovación tecnológica, con productos y servicios financieros digitales que están siendo adoptados con naturalidad por los clientes, que implican cambios en sus hábitos y en el uso de los canales tradicionales que ofrece la Banca: Internet y el teléfono móvil se han convertido ya en el medio natural para interactuar con el banco, quedando en el olvido acudir físicamente a una sucursal. El cliente demanda interactuar con su entidad financiera con la misma facilidad que se comunica con un

amigo/a a través de una red social, mediante un correo electrónico o incluso mediante lenguaje natural. Esta facilidad es posible gracias a la evolución de la tecnología y han aparecido unos nuevos actores, sector Fintech, que sin ser bancos, ofrecen a los clientes esta sencilla funcionalidad, mediante servicios más ágiles y cómodos para el cliente. Todo ello está provocando que la banca tradicional se vea obligada a transformarse digitalmente, mediante estrategias innovadoras centradas en el cliente, ofreciéndole una atención personalizada y permitiéndole interactuar con aquello que se siente más cómodo: manteniendo una conversación en lenguaje natural con su propio teléfono móvil o tableta. En este contexto, el sector bancario tradicional debe aprovechar, como ventaja competitiva, la cantidad ingente de datos que dispone de sus clientes para que a través de la sinergia entre Inteligencia Artificial (Machine Learning y Deep Learning), Analítica de Datos, Big Data y Estadística, extraiga el conocimiento oculto y ofrecer una banca privada y personalizada al cliente. Un cliente genera a diario mucha información financiera que almacena su banco: cuándo, qué y dónde realiza sus compras o qué gastos e ingresos mensuales tiene; esta cantidad de datos que diariamente aportan los clientes a su banco, que hasta el momento no genera valor, debe ser analizada para extraer su conocimiento oculto y ofrecer servicios inteligentes de valor añadido para el cliente que le aporten una atención personalizada y a medida. El teléfono móvil, su tableta o incluso su televisión serán los nuevos canales con los que el cliente interactuará, mediante una conversación en lenguaje natural, para acceder a servicios inteligentes de valor añadido que le proporcionen una mejor salud financiera y satisfacción con su banco.

## II. TESIS: DESCRIPCIÓN DE LA INVESTIGACIÓN

La Banca conoce con absoluta precisión los movimientos de sus clientes: qué hace, dónde y cuándo (la información estructurada tradicional) y si además, es capaz de agregarle datos externos del cliente (información no estructurada): redes sociales, geolocalización, actividad en Internet o qué productos le interesan, compondrá una gran base de datos, que a partir de la sinergia entre Inteligencia Artificial, Analítica de Datos, Big Data y Estadística, le permitirá conocer con exactitud a cada uno de sus clientes, para ofrecerles una banca personalizada y privada, justo en el momento que lo demandan, para conseguir su satisfacción y fidelización. La banca es el sector más adecuado para aprovechar estas tecnologías y el momento es ahora, para dar origen a la Banca 3.0, con el horizonte de proporcionar al cliente servicios inteligentes de valor añadido y la información necesaria para una toma de decisiones adecuada y lo más importante, hacerlo de forma anticipada, es decir, prever las necesidades concretas del cliente. Para conseguirlo es necesario que la Banca tenga un conocimiento de 360° del cliente.

El objetivo de mi tesis doctoral es investigar qué servicios inteligentes de valor añadido se pueden ofrecer a los clientes a partir de la sinergia entre Inteligencia Artificial, Analítica de Datos, Big Data y Estadística, dando soporte a una Cuenta Inteligente 2.0 que ofrezca servicios innovadores y exclusivos al cliente y que éste pueda consumirlos utilizando lenguaje natural, a modo de conversación, simulando una conversación con su agente financiero tradicional.

Los tres principales objetivos que se pretenden conseguir durante el desarrollo de esta tesis doctoral son:

1: Predecir gastos de consumo del cliente en transacciones no fijas (no periódicas) como son: gastos habituales del hogar (luz, agua o gas), gastos en la cesta de la compra y gastos derivados de ocio y restaurantes. El cliente, mediante su voz, podrá solicitar una predicción de cualquiera de sus gastos con la antelación que requiera en ese momento: podrá consultar a qué cantidad ascenderá su recibo de luz el próximo trimestre, o de la misma forma, podría preguntar, en lenguaje natural, cuál es la predicción de gastos que tendrá en la próxima Navidad, e incluso podrá solicitar el detalle de los mismos: qué gastos serán relacionados con la cesta de la compra o cuáles serán los referidos a ocio y restaurantes. Disponer de una predicción de gastos le ofrece al cliente la posibilidad de tomar mejores decisiones y anticiparse a posibles situaciones desfavorables, lo que le permite tener una mejor salud financiera. Imaginemos que un cliente desea saber cuáles serán los gastos de luz y agua que tendrá al finalizar el mes de septiembre para poder tomar decisiones sobre cómo afrontar la compra de libros y material de sus hijos/as en septiembre, etapa de *'vuelta al cole'*. La disponibilidad de este servicio de predicción de gastos puede ayudar al cliente a modificar su comportamiento (y el de su unidad familiar); si se predice, de forma anticipada, un determinado pico en un gasto de

consumo, el cliente podrá modificar su comportamiento para tartar de reducir esa previsión de gasto.

También en este punto se conseguirá predecir posibles descubiertos en cuenta para adoptar una solución de forma anticipada; notificar al cliente que, siguiendo su tendencia actual, pasado unos meses, quedará sin saldo en su cuenta, tendrá como consecuencia una modificación de su comportamiento para tratar de evitarlo o incluso recomendar una solución financiera, a medida, como veremos en el siguiente punto.

2: Realizar recomendaciones en base a la actividad financiera del cliente, es decir, en función de los movimientos, gastos e ingresos, que realiza a diario: analizando los movimientos que diariamente realiza el cliente, la cuenta inteligente le ofrecerá recomendaciones sobre productos que se ajustan a sus necesidades y que le aportan una solución financiera *'ah doc'* que le permite salvar una situación concreta en un momento determinado; esta recomendación, en tiempo real, mejorará su experiencia y satisfacción con la entidad, percibiendo una atención totalmente personalizada y a través de una conversación en lenguaje natural con su teléfono móvil o tableta, como si se tratara de una reunión con su agente financiero tradicional habitual. Imaginemos que un cliente tiene pocos ingresos y siempre compra a débito, la cuenta inteligente le recomendará una tarjeta con crédito, con la cantidad justa adicional que suele necesitar mensualmente y que la pueda contratar, de forma fácil y rápida, simplemente indicándolo: *'quiero solicitar mi tarjeta de crédito'*. En este servicio, también se puede incluir el análisis de las publicaciones en las redes sociales del cliente, siempre que sean datos públicos y no datos privados, para analizar su actividad y hacerle recomendaciones; imaginemos que un cliente publica en redes sociales fotos y comentarios sobre el coche deseado, el servicio de cuenta inteligente le ofrecerá un crédito personalizado para su financiación y que lo pueda contratar cómodamente, a viva voz, indicando: *'quiero solicitar mi préstamo para la compra de ese coche'*. Recibir recomendación de productos financieros ergonómicos, a medida y personalizados, que se puedan contratar en pocos segundos con su propia voz y casi sin la habitual burocracia documental, provoca la satisfacción del cliente, su fidelización y mejora su salud financiera.

3: Comparar gastos con clientes anonimizados de perfil similar: frecuentemente, con familiares o amigos/as, tratamos de comparar los gastos de consumo de suministros habituales, para tratar de tener un indicador de nuestra actividad en el hogar. Con este servicio, el cliente tendrá una referencia o indicador que le permita evaluar si sus gastos en suministros están alineados con otros clientes de perfil similar. Esta comparativa se realiza utilizando datos agregados y anonimizados de clientes con el mismo perfil, en tiempo real. La cuenta inteligente le indicará al cliente, mediante lenguaje natural, si un gasto concreto en un consumo habitual está

alineado con la media de sus perfiles similares. Un perfil similar será un cliente con sueldo, en la misma horquilla salarial, misma dimensión familiar, igual tamaño de vivienda y misma ciudad. Este servicio permitirá al cliente analizar su propio comportamiento (y el de su unidad familiar) de forma autónoma, detectando si hay una desviación importante entre sus gastos y los de perfiles similares, haciendo especial hincapié en los gastos derivados de los consumos habituales. La notificación de estos desvíos, puede alertar al cliente de nuevos comportamientos inadecuados, averías en el suministro u otros motivos; gracias a la notificación, se puede corregir la situación. Imaginemos que el recibo de agua trimestral del cliente asciende a 200 € y sus perfiles similares tienen un gasto de 100 €, la mitad; se abre un escenario de análisis donde el cliente podrá estudiar qué comportamiento ha motivado el pico de consumo; quizás se trata de un consumo esperado por una situación puntual o se pudiera deber a una fuga de agua desconocida. Nuevamente, este servicio mejora la salud financiera del cliente y por tanto su calidad de vida.

### *Tesis: Hipótesis de partida*

Esta cuenta inteligente de servicios innovadores de valor añadido para el cliente se podrá desarrollar en base a la ingente cantidad de información que registra una entidad financiera a partir de sus movimientos. Empleando técnicas de Machine Learning y Minería de datos, se pretende encontrar patrones de comportamientos de los clientes para predecir gastos, diseñar productos financieros a medida y comparar comportamientos del cliente con perfiles similares anonimizados.

Además, la entidad financiera dispone de los datos de un cliente desde el día que se da de alta en el banco hasta el momento actual; cuanto más tiempo de antigüedad tenga un cliente, más precisos serán sus modelos de comportamiento; o lo que es lo mismo, a medida que avance el tiempo, mientras pertenezca al banco, sus patrones cada día serán más precisos. Con cada nuevo movimiento u operación que realiza el cliente (nueva compra o cargos de gastos de consumo) sus patrones de comportamientos serán más reales y ajustados. El tipo de cliente que más destaca en un banco es aquel que dispone de una cuenta, donde tiene asociada la hipoteca y la nómina; este tipo de cliente suele permanecer muchos años en el mismo banco, tantos como años esté suscrita su hipoteca. Con un horizonte tan largo en el tiempo, los patrones y modelos de comportamiento para el cliente serán muy ajustados y conseguirán dar soporte a los servicios inteligentes de valor añadido descritos.

Por otro lado, para poder ajustar y ser más preciso en la predicción de gastos de consumo que un cliente podrá generar, al cabo de unos meses, será necesario utilizar información externa, a dos niveles:

1: Utilizar la información pública que un cliente publique en sus redes sociales. Si el cliente publica fotografías y comentarios de su viaje en próximas semanas, durante la etapa estival, el servicio inteligente deberá tenerlo en cuenta; la predicción de gastos de consumos habituales del hogar será

menor, pero crecerá la predicción en los gastos de ocio y restaurantes.

2: Consultar las variaciones de tarifas de los proveedores de servicios relacionados con el consumo del hogar: luz, agua, gas, tarifa telefónica (caso que no sea tarifa plana), etc. Habitualmente, con la llegada de un nuevo año, el temido mes de Enero, suelen subir las tarifas del proveedor del servicio de agua o luz. Para realizar una predicción más certera, será necesario consultar, de forma automática y transparente al cliente, cuál será la subida de la tarifa. En la actualidad, en plena transformación digital de todas las organizaciones, se están apificando sus servicios, por lo que gracias a las APIs la cuenta inteligente podrá tener acceso a las nuevas tarifas y políticas de precios de los proveedores de servicios de consumo así como a otros terceros que utilice el cliente.

En la actualidad las entidades financieras no están generando valor sobre esta cantidad de información de un cliente por lo que no pueden encontrar modelos y patrones que les permita predecir comportamientos; los clientes demandan servicios de valor añadido porque quieren que su entidad financiera les ofrezca los mismos servicios inteligentes que ya ofrecen hoy día las plataformas web 3.0: redes sociales, mensajería, correo electrónico, etc.

### III. ORIGINALIDAD DE LA TESIS

La cuenta inteligente y los servicios innovadores de valor añadido que se le ofrecen al cliente provocará una revolución en el sector financiero dando origen a lo que se conoce como Banking 3.0: los clientes demandan una transformación digital en los servicios financieros que reciben de su banco y reclaman poder interactuar con sus productos y cuentas tal y como lo hacen con los servicios más novedosos de las plataformas más populares de Internet.

La originalidad de esta tesis doctoral se basa en los siguientes cuatro apartados:

#### *A. Interacción mediante la voz del cliente*

El cliente podrá interactuar mediante lenguaje natural con los servicios innovadores de valor añadido que le ofrece la cuenta inteligente; la forma más natural de comunicación entre las personas es el lenguaje y es el medio de interacción con el que un cliente se siente más cómodo (no hay otro mejor, por muy cuidada que resulte la interfaz de la aplicación).

Coger el dispositivo móvil, activar un solo clic para iniciar la conversación con el 'software - bot', que conoce al cliente a la perfección y poder realizar preguntas o llevar a cabo acciones con la forma de expresarse el cliente, va a suponer una auténtica revolución en el sector financiero. Resulta importante hacer hincapié en que, sea cual sea el nivel cultural del cliente, su dominio del vocabulario y su forma de expresión, el servicio inteligente se adaptará y tendrá la capacidad de responderle adecuadamente y realizar las acciones que le solicite el cliente. En ningún caso será necesario indicar frases predefinidas para realizar una tarea concreta; una misma acción podrá ser invocada de múltiples formas de expresión según la propia idiosincrasia del cliente.

A continuación, se indican algunos ejemplos de preguntas y acciones que podrá realizar el cliente:

- ‘¿cuánto pagaré en mi recibo de agua el próximo trimestre?’
- ‘¿qué previsión de gastos en ropa tendré la próxima Navidad?’
- ‘¿cuánto gastaré en gasolina durante el verano?’
- ‘¿cuánto me subirá el recibo de luz el próximo año?’
- ‘mis gastos en gas, ¿es mucho o poco?’
- ¿cuánto pagan mis vecinos en luz?
- quiero solicitar una tarjeta de crédito para mi hija que se va al extranjero a estudiar durante un año.

El sector bancario está muy exigido por la regulación y se deben cumplir estrictas medidas de seguridad en cuanto a la ley de protección de datos; el consentimiento del cliente autorizando cada una de las operaciones o consultas quedará grabado, a modo de prueba o verificación. Esto implica otra ventaja importante, se reduce la burocracia de tener que firmar muchos documentos o enviarlos a la oficina. Con una frase como ‘*sí doy mi consentimiento*’ será suficiente para que el servicio inteligente quede autorizado a realizar la operación o la consulta sobre la cuenta del cliente. Esta forma de funcionar, provocará otra revolución en el sector financiero.

Por su puesto, el cliente también podrá interactuar con los servicios inteligentes a través de la interfaz de la tradicional aplicación, pero lo realmente original y novedoso es poder hacerlo manteniendo una conversación en lenguaje natural: no hay botones, ni opciones que marcar, ni campos que rellenar, simplemente se debe mantener una conversación, con el nivel de expresión habitual del cliente.

### B. Predecir gastos y descubiertos

La cuenta inteligente ofrecerá al cliente un servicio de predicción de gastos sin ninguna restricción de temporalidad con el objetivo de anticiparle, de forma precisa, los cargos que ocurrirán en su cuenta en un futuro. Esta predicción permitirá al cliente una mejor toma de decisiones en su día a día y le dotará de una potente herramienta revolucionaria para analizar su comportamiento y poder modificarlo en función de las predicciones que reciba. Conocer de forma anticipada los gastos, repercute en una mejor salud financiera del cliente; cuanto mayor antigüedad tenga el cliente en el banco, las predicciones serán más precisas; con cada nuevo movimiento, el sistema aprenderá y ajusta mejor la predicción de gastos.

En una unidad familiar que pretenda ahorrar o reducir gastos, será un servicio innovador muy útil que permita al cliente poder modificar sus hábitos sobre los consumos habituales, agua, luz o gas, y conseguir ahorrar para diversificar su capital y poder hacer frente a otras situaciones.

Ejemplos de situaciones innovadoras de ese servicio de predicción son los siguientes:

- ‘¿cuánto pagaré de gas el próximo invierno?’; a partir de esa cuantía, la unidad familiar puede adaptar su

comportamiento, bien para reducirlo en una política de ahorro, o bien, usar un mayor número de horas la calefacción y vivir el invierno con mayor confort en el hogar.

- ‘¿cuánto gastaré en restaurantes de mi localidad durante las vacaciones en Semana Santa?’; quizás ese dato pueda modificar los planes de la unidad familiar y se adopte otro plan que por el mismo valor económico, puedan disfrutar de mayores servicios.
- ‘¿cuál será el total de gastos (agua, luz y gas) que tender en casa durante este verano?’; en función de ese dato, quizás las vacaciones de verano se diseñen de forma distinta o ayude a planear el periodo estival.
- ‘¿cuándo se quedará la cuenta destinada para cargos de gastos del hogar sin fondos?’; a partir de la fecha indicada, el cliente evitará un descubierto en su cuenta, lo que implica evitar una pérdida del servicio (no tendrá un corte de agua o de luz en su domicilio). Una vez conocida la fecha en la que ocurrirá el descubierto, el cliente ya puede tomar la decisión de cuándo es más adecuado aumentar el saldo de aquella cuenta y evitar una situación que le puede acarrear incomodidad por la pérdida del servicio e incluso algún recargo.

### C. Comparar gastos con perfiles similares anonimizados

Dotar al cliente de una herramienta que le permita tener un indicador o referencia de cómo son los gastos que genera su unidad familiar provocará una auténtica revolución en el sector financiero. Que el cliente pueda preguntar con su propia forma de expresión, en lenguaje natural, si el gasto de luz trimestral es adecuado o no, le dará una potente herramienta que le permitirá analizar su comportamiento y en caso necesario, corregirlo.

En la actualidad, ningún banco ofrece este servicio y habitualmente es demandado, de forma indirecta, por cualquier ciudadano/a. Siempre que se recibe un gasto derivado del consumo del hogar (luz, agua o gas), nos genera cierta incertidumbre de si esa cantidad es similar a la de un cliente con sus mismas condiciones y características. Disponer de este indicador, modificará los comportamientos de los clientes, homogeneizando los gastos con los de perfiles similares y por tanto, mejorando la salud financiera del cliente. Este indicador puede alertar al cliente de comportamientos inadecuados en el consumo de los servicios del hogar, detectar que se ha contratado una potencia del servicio que no es similar a la de sus vecinos o incluso posibles errores en la facturación que se le está aplicando al cliente. Todo ello, radica en una optimización adecuada del uso de los servicios de consumo del hogar y por tanto una mejor salud financiera.

El cliente podrá utilizar este servicio inteligente, mediante lenguaje natural para preguntar cómo son sus gastos con respecto a los de sus semejantes. El servicio inteligente, responderá cuál es la media de gastos para perfiles similares y

si el cliente está gastando una mayor o menor cantidad en un servicio de consumo del hogar concreto. Veamos dos ejemplos:

Ejemplos de situaciones innovadoras de ese servicio son los siguientes:

- *‘¿es adecuado lo que estoy gastando en luz en lo que llevamos de invierno?’ El servicio responderá, analizando lo que llevan gastado perfiles similares, indicando si el gasto del cliente está por encima o es inferior a la media de sus perfiles similares.*
- *‘en verano, ¿cuánto he gastado más de agua que mis vecinos?’; el servicio analizará el gasto de agua de sus vecinos, que tengan un perfil similar, hallará la media aritmética de todos y la comparará con el gasto del cliente.*

#### D. Recomendar productos financieros personalizados

Entre los servicios inteligentes de valor añadido que se ofrecen al cliente con esta cuenta inteligente aparece la recomendación de productos financieros personalizados y diseñados a la medida del cliente; el banco conoce perfectamente los movimientos del cliente y que productos se adecúan a sus necesidades. Este servicio de recomendación inteligente está disponible en las dos siguientes modalidades:

1: Recomendación a petición del cliente: Hasta el momento, el departamento de Marketing de la Entidad únicamente ofrecía dos o tres productos anuales para todos sus clientes, siguiendo una estrategia horizontal, sin tener en cuenta las características propias de cada cliente. Con este servicio de cuenta inteligente, el cliente podrá solicitar, mediante lenguaje natural, productos financieros a medida que mejoren su salud financiera. Veamos dos ejemplos:

- *‘Quiero invertir en un fondo de inversión, ¿qué nivel de riesgo me recomendarías?’*
- *‘Según mi actividad económica, qué modalidad de crédito me recomiendas: ¿fin de mes o aplazado?’*

2: Recomendación automática: de forma proactiva, el servicio de recomendación inteligente tendrá la capacidad de detectar situaciones que pueden perjudicar al cliente y diseñar un producto financiero personalizado para evitarlo. Este servicio revolucionará el sector financiero porque conseguirá la satisfacción del cliente. Cuanto más precisos y ergonómicos sean los productos recomendados al cliente, mejor será su salud financiera. En la actualidad, la Banca no dispone de este servicio, siendo totalmente reactivos y en la mayoría de los casos la recomendación llega cuando previamente el cliente ha solicitado información o ha transmitido la situación que le perjudica. Disponer de un sistema de recomendación automático que tiene la capacidad de predecir una situación desfavorable para el cliente y proporcionar una solución que la evite o le genere mayor beneficio, tendrá como consecuencia,

un gran impacto en el sector financiero. Veamos dos ejemplos de este servicio:

- *‘Un cliente con ingresos y gastos equilibrados mensualmente, únicamente dispone de tarjeta de débito; el servicio inteligente le recomendará una tarjeta de crédito, con una cuantía de crédito ajustada a sus necesidades’*
- *‘El cliente dispone de un fondo de inversión que ha comenzado a bajar su interés y se preve que continúe el descenso; el sistema le recomendará cambiar de fondo de inversión y además, le indicará cuál es el más adecuado para él en ese momento’.*

## IV. METODOLOGIA

Esta tesis doctoral se está desarrollando siguiendo una metodología Agile para conseguir los dos siguientes objetivos:

1: Realizar entregas rápidas y continuas: el proyecto de cuenta inteligente se ha dividido en pequeñas partes que tienen que completarse y entregarse cada dos semanas; se define un trabajo concreto y asumible en ese espacio temporal concreto. El feedback con el tutor resulta mucho más eficiente acotando las tareas.

2: Dotarlo de flexibilidad ante los cambios: a medida que se avanza en el desarrollo y se va obteniendo inferencia del conocimiento oculto en los datos de los clientes, puede ocurrir que cualquiera de los servicios inteligentes sufra modificaciones. Tener que modificar no supone un paso atrás, sino que cualquier nuevo requisito será bienvenido para tratar de mejorar los servicios inteligentes a modelar.

Cada dos semanas se vuelven a diseñar las nuevas tareas a realizar en el siguiente periodo, volviendo a incorporar las que no se hayan podido realizar o estuviesen bloqueadas por algún factor externo. Esta forma de trabajar está resultando bastante productiva y eficiente, porque cada dos semanas se conoce de antemano qué tareas estarán desarrolladas y al estar perfectamente acotadas, se puede verificar rápidamente su desarrollo y ejecución.

## V. PLAN DE TRABAJO

El desarrollo de esta tesis doctoral comenzó en Noviembre de 2017 y el plan de trabajo diseñado es el siguiente:

### 1. Disponer de la base de datos de los clientes

Se ha partido de una base de datos de una entidad financiera de la República Checa que en 2012 publicó datos financieros de clientes anonimizados. La base de datos contiene datos de 1.700 clientes entre los años 1992 y 1998. La base de datos cuenta con las siguientes cinco tablas:

*Cientes:* Id del cliente, sexo, fecha nacimiento y distrito al que pertenece.

*Cuentas:* Id de la cuenta, id del cliente al que pertenece, fecha de alta y frecuencia de acceso. Un cliente únicamente pertenece a una cuenta.

*Tarjetas:* Id tarjeta, fecha de alta, cuenta a la que está asociada y tipo de tarjeta (classic, gold o junior). Un cliente como máximo tiene una sola tarjeta; hay clientes sin tarjeta.

*Préstamos:* Id préstamo, cuenta a la que está asociado el préstamo, fecha alta, cantidad total, número meses y cantidad mensual de pago. Un cliente como máximo tiene un solo préstamo; hay clientes sin préstamo.

*Transacciones:* Id transacción, cuenta sobre la que se realiza la transacción, fecha, si es periódica o no, si es cargo o abono, cantidad de la transacción y motivo de la transacción. Un cliente tiene asociadas 'n' transacciones.

## 2. Componer una única tabla

Con el objetivo de utilizar los datos en herramientas de Machine Learning, se ha compuesto una única tabla que contenga toda la información de la base de datos financiera. Cada fila de esta única tabla está compuesta de las 5 siguientes partes: Cliente, Cuenta, Tarjeta, Préstamo y Transacción. La relación entre Cliente, Cuenta, Tarjeta y Préstamo es 1:1, y la relación entre Cliente y Transacción es 1:n, por tanto, por cada transacción asociada al cliente, se repetirán las cuatro primeras partes (cliente, cuenta, tarjeta y préstamo).

## 3. Revisar y limpiar 'ruido'

Tras una revisión exhaustiva, se han encontrado datos que no aportan valor y se han eliminado. Concretamente, se han encontrado transacciones, de tipo cargo en cuenta, asociadas a distintos clientes con una cuantía de 0 €; dado que no aportan valor, se han eliminado dichas transacciones.

## 4. Definir objetivos

Los objetivos que se pretenden conseguir con el desarrollo de esta tesis son los siguientes:

- 4.1: predecir los gastos de consumo del hogar (lug, agua, gas)
- 4.2: comparar gastos de consumo con perfiles similares anonimizados.
- 4.3: recomendar productos financieros a medida y personalizados que mejoren su salud financiera.

## 5. Análisis descriptivo de la base de datos

Se ha realizado un análisis estadístico y descriptivo de la base de datos para descubrir correlaciones entre las variables y analizar la viabilidad de la base de datos para solucionar el problema propuesto. En primer lugar se realizó un análisis univariable para tener información de cada una de ellas y a

continuación un análisis bivariado comparando las variables de gastos de consumo a predecir con el resto de variables. El resultado de este análisis descriptivo concluye que sí es viable conseguir los objetivos propuestos con los datos disponibles.

## 6. Generar y validar modelos

Mediante la herramienta de software libre Weka se están aplicando distintos algoritmos para comprobar cuál se comporta mejor y obtiene una mayor correlación entre variables. A partir del resultado de estos algoritmos, se generarán y validarán los modelos que nos permitirán predecir gastos de consumo del hogar para cada cliente. Los modelos generados también ayudarán a conocer la situación financiera del cliente para recomendar productos personalizados y comparar gastos con los perfiles similares anonimizados.

## 7. Elegir el modelo más adecuado

Comparar los resultados obtenidos en cada modelo y elegir aquel que presente mejores prestaciones para conseguir cumplir los objetivos propuestos.

## 8. Tratamiento lenguaje natural

Diseñar el software adecuado para permitir al cliente interactuar con la cuenta inteligente mediante lenguaje natural en los dos sentidos: cliente – aplicación y viceversa.

## 9. Conclusiones

Comprobar si se cumple la hipótesis de partida y las conclusiones sobre el grado de certidumbre en las predicciones realizadas, la afinidad en la comparación de gastos y la adecuación de los productos financieros a medida recomendados.

## VI. CONCLUSIONES

El desarrollo de esta tesis doctoral tendrá un gran impacto en el sector financiero y la Sociedad y más concretamente, en sus clientes, mejorando su salud financiera, satisfacción y por tanto su fidelización en la entidad. En la actualidad, ningún banco ofrece a sus clientes predicción de gastos, indicadores de comportamientos o recomendación de productos personalizados que les aporten un mayor beneficio, en tiempo real y que todo ello, lo puedan hacer mediante una conversación con su teléfono móvil, sea cual sea su forma de expresarse. Por otro lado, esta tesis también tendrá un gran impacto en la comunidad científica ya que hasta el momento, por la propia idiosincrasia idiosincrasia de las entidades financieras, que no liberaban sus datos, no proliferan las investigaciones sobre predicción de gastos, analizadores de comportamientos ni recomendaciones de productos financieros personalizados. Esta tesis doctoral permitirá cambiar la relación tradicional del cliente con su banco, suponiendo un importante hito en la Sociedad.



# Deep Neural Networks for Statistical Downscaling of Climate Change Projections

1<sup>st</sup> Jorge Baño-Medina

*Grupo de Meteorología*  
*Instituto de Física de Cantabria*  
 (CSIC-UC) Santander, Spain  
 bmedina@ifca.unican.es

2<sup>nd</sup> José Manuel Gutiérrez

*Grupo de Meteorología*  
*Instituto de Física de Cantabria*  
 (CSIC-UC) Santander, Spain  
 gutierjm@ifca.unican.es

3<sup>rd</sup> Sixto Herrera

*Grupo de Meteorología*  
*Dept. Applied Mathematics*  
 and Computing (UC) Santander, Spain  
 herreras@unican.es

**Abstract**—Global Climate Models (GCMs) are the main tool to predict the future evolution of the atmosphere at different time scales, from weather forecast (for the next few days) to climate change projections (where the forcing effect of greenhouse gases drives future climate trend projections for the next few decades). The main limitation of GCMs is their limited spatial resolution (hundreds of kilometers for climate change applications). A number of *statistical downscaling* techniques have been proposed in the last two decades to increase the resolution of these predictions taking into account the relationships between model outputs and local observations of the variables of interest. Besides the classical approaches based on (generalized) linear regression or analogs, a number of machine learning approaches have been applied to this problem. However, there is general consensus that only limited added value is obtained with these techniques when jointly considering model performance, interpretability and parsimony. In this Thesis we analyze the potential of deep learning in this field, which is yet unexplored. In particular, we analyze the promising properties of convolutional neural networks using as benchmark a recent intercomparison experiment of over 50 statistical downscaling methods over Europe (VALUE initiative, <http://www.value-cost.eu>). Some promising results are reported for a first illustrative example (precipitation occurrence), showing that these models automatically handle redundancy and perform geographical and variable selection/transformation of predictors in a robust and spatially consistent form. The relevance of this new approach is discussed in the context of a number of international initiatives where this Thesis will contribute.

**Index Terms**—climate change, statistical downscaling, deep learning, convolutional neural networks

## I. INTRODUCTION

Global Climate Models (GCM) are key tools to simulate and predict the evolution of the climate system by numerically solving the physical equations governing its different components (atmosphere, hydrosphere, cryosphere, lithosphere) and the interactions among them [1], [2]. These models are solved over a 3D grid discretizing the globe (latitude, longitude, and height) and provide information for a large number of climatic variables, with typical spatial and temporal resolutions of hundreds of kilometers and days, respectively. GCMs are crucial for studying the future evolution of the climate and for assessing the impacts of climate change under different socio-economic emission scenarios (different plausible evolutions of

concentrations of greenhouse gases in the atmosphere). For instance, politicians have recently adopted mitigation climate measures in the historical 2015 Paris agreement based on the assessment provided by the Intergovernmental Panel on Climate Change (IPCC) [3], which builds mainly on GCM projections for the present century [4].

One of the main practical limitations of GCMs is that they do not solve regional to local processes due to its coarse resolution, specially in areas where local phenomena are relevant (e.g., coastal areas and/or complex topography regions). Regional and local climate information is crucial to determine the effects of climate change in different impact areas, such as hydrology, agriculture and energy production. In order to bridge this gap, a number of statistical downscaling (SD) [1] techniques have been developed during the last two decades building on empirical relationships established between informative large-scale atmospheric variables provided by GCMs (predictors, e.g. humidity or temperature at different atmospheric height levels) and observational records of the variables of interest at regional/station scale (predictands). These relationships are learned using simultaneous daily records for predictors (normally obtained from a retrospective forecast dataset) and observational variables for a ( $\sim 30$  years) historical period (more details in [2], [5]). To generate future regional projections, the statistical models learned in a historical period are then applied to (the predictors from) future GCM projections. This poses a number of methodological issues that are analyzed in detail in Section II.

Besides the classical SD techniques based on linear approaches (e.g., generalized linear models) or non-parametric techniques (e.g., analogs) [6], a number of sophisticated machine learning techniques have been applied to this problem. For instance, the first applications of neural networks are dated back in the late 90s [7], [8]. The problems related to nonconvexity, time-consuming learning, and overfitting drove attention to alternative machine learning approaches, such as support vector machines (SVMs) [9] or random forests [10], [11]. However, there is general consensus that no method clearly outperforms the others and, in general, only limited added value is obtained with nonlinear techniques in the context of climate change when considering model performance, interpretability and parsimony [7], [12], [13], [14].

We acknowledge financial support from the project MULTI-SDM (CGL2015-66583-R, MINECO/FEDER).

Machine learning is currently a very active research area, boosted by the major deep learning (DL) breakthroughs in the field of neural networks (see [15] and references therein). Deep learning extracts high-level feature representations in a hierarchical way due to its (deep) layered-structure whose unit elements (neurons) are connected by adjustable weights. Different combinations of convolutions, auto-encoders and/or classic fully-connected layers allow to model a variety of problems in several disciplines. Moreover, new efficient learning methods (e.g. batch, stochastic, and mini-batch gradient descent), regularization options (e.g. dropout), and frameworks (e.g. TensorFlow) allow to efficiently learn these models from (big) data, avoiding overfitting. However, finding the adequate topology for a particular problem is still a challenging step. Particularly in computer vision, deep learning has outperformed against other machine learning techniques with a specific topology called deep convolutional neural network (CNN). CNN was first introduced in [16], appeared as a neural network specially designed for regular grid-structure inputs such as images (2D). The characteristic of CNN is that the parameters convolute over the 2D map, exploiting the spatial structure and resulting into fewer parameters than traditional neural networks. Thus, the layers consists in a set of neurons spatially arranged called maps or filters that represents the spatial distribution of a particular feature learned by the net. The deeper the network, the more complex the features are in the filter maps.

Deep learning is a very active topic in many communities, such as bioinformatics [17]. In the case of meteorology and climate, there are only a few applications of deep learning such as the estimation of cyclone's intensity [18], the detection of extreme weather events [19] or a first approach for downscaling [20], among others. The latter establishes an analogy between images and atmospheric fields to generate super-resolution precipitation images and set the path for the application of deep CNN in statistical downscaling.

In this Thesis we will undertake a comprehensive analysis of deep learning for statistical downscaling of climate change projections, analyzing the adequacy of different components and topologies for this problem and assessing the underlying assumptions and methodological issues required for a robust applications of deep CNN in this field. We also analyze the replicability and explicability of results in order to gain confidence in these techniques, which are currently seen as black-box methods by the climate community. We will build and contribute to standard experimental frameworks and international initiatives focusing on statistical downscaling (e.g. IPCC, VALUE [21] and CORDEX [22]) and use as benchmarks the state-of-the-art methods developed therein. In particular, we will consider a recent intercomparison experiment of over 50 statistical downscaling methods over Europe developed in the framework of the VALUE initiative, which constitutes the largest to date intercomparison of statistical downscaling methods [6]. This approach will maximize the diffusion and impact of the results of this Thesis.

## II. HYPOTHESIS AND METHODOLOGY

Statistical downscaling methods have to fulfill three assumptions in a climate change context in order to provide plausible results and to avoid statistical artifacts [1]:

- 1) *Explanation of local variability*: The methods should explain a large fraction of local variability in order to provide an informative link between the large scale (predictors) and the local scale (predictands). Besides the choice of the downscaling technique, the selection of informative predictors over suitable geographical domains plays a key role here in order to convey the appropriate large scale information to downscale the variable of interest (e.g. precipitation or temperature). This assumption is assessed using a variety of validation metrics, which measure (directly or indirectly) the percentage of local variability explained by the downscaling method. In this Thesis we will build on the previous work done in the VALUE initiative for the validation of statistical downscaling methods [21].
- 2) *Selection of robust predictors*: Since the downscaling methods are trained in a historical period using predictors from a retrospective GCM forecast (and simultaneous observations) and then applied to predictors from different GCM future projections, it is required that the predictors are realistically simulated by the different GCMs in present/historical climate. Therefore, suitable predictors for climate change studies typically restrict to large scale variables (such as pressure, wind components, temperature and humidity) at different heights (e.g. 850 and 500 mb, corresponding approximately to 1500 and 5000 meter above sea level, respectively). Surface variables (apart from sea level pressure or surface temperature) are commonly not used as predictors, since they strongly depend on the particular topography/resolution used by the GCM.
- 3) *Extrapolation capability*: This is a key requirement for SD methods, since the future climate change signal may be artificially biased otherwise. Therefore, the structure of the statistical downscaling method should provide extrapolation capabilities to future climates. This implies that the predictors used are credibly projected into the future by the GCM and that the statistical downscaling method can extrapolate out-of-sample records. Therefore, good cross-validation performance is a necessary but not sufficient requirement, since the values of predictors in future climates can be far away from the historical climate. Additional cross-validation experiments with pseudo-observations (using future model predictions as observations, since observations of the future climate are not available) have been suggested for this task and will be used in this Thesis [21].

As a consequence of these requirements, predictors must be carefully selected (both the particular variables and the geographical region of influence) in order to obtain credible results. Atmospheric predictors are very redundant and the



same event can be driven by completely different physical processes depending on the region. As a consequence, identifying the adequate informative predictors —both the variables and the geographical regions of influence— for a certain task (e.g., downscaling precipitation) is a major challenge in statistical downscaling. For instance, this problem was reported in the largest to date intercomparison of standard SD methods performed in the VALUE initiative (<http://www.value-cost.eu>) as one of the most time-consuming tasks in most of the cases. Predictor selection was typically undertaken applying tedious feature selection (e.g., stepwise algorithm) and/or feature reduction (e.g., principal component analysis) techniques [6]. Moreover, when considering large continental domains (Europe in VALUE) most of the methods tackle the predictor selection task by subdividing Europe in 8 regions (see Figure 1), which hinders transferability to other domains.

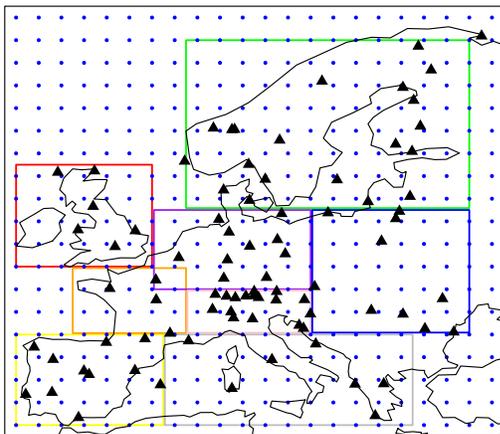


Fig. 1. Geographical domain indicating the reanalysis' gridboxes or predictors ( $2^\circ$  resolution, blue dots, aprox. 200 km) and the location of 86 stations or predictands (black triangles). The coloured boxes show 8 subregions, illustrating how traditional regions need to split big domains into subdomains due to dimensionality constraints; more details in [6].

In principle, machine learning techniques could help with these problems, allowing to develop automatic SD methods based on the available data, building on automatic feature selection approaches. In particular deep learning and in particular CNNs seem to be ideal candidates for this problem since convolutional layers could deal with the problem of selecting informative geographical regions for each predictand (e.g. location), whereas fully-connected layers could model potential nonlinearities connecting large and local scales. In Section IV we show some first results indicating the suitability of CNNs for this purpose.

Another disadvantage of statistical downscaling is that is very dependent on both the quality and quantity of data, in order to infer reliable models. This poses serious problems for downscaling in regions that lack of data, such as the Antarctica or Africa. Traditionally in these cases dynamical downscaling is preferred (see [22] for a review), due to the incapacity to infer the parameters of a statistical model. In this Thesis we will try to address this issue by using the concept of *transfer learning*, present in multi-task neural networks [23].

For downscaling problems, transfer learning can be interpreted as a way to answer the following question: can information of a certain region be useful to downscale climate in another place on the planet? Transfer learning has been successfully applied in other fields, such as natural language processing [24] and computer vision [25]. Furthermore, we believe that the ability to simultaneously downscale to various locations will result in more spatially coherent downscaling, very important in impact studies.

Fortunately, new sophisticated software and computation sources have been developed in order to ease the implementation of deep neural networks, permitting the construction of versatile and complex architectures. In particular, we will use the package TensorFlow [ref], which facilitates the solid implementation of CNNs using the most relevant deep learning advances. Among them, we can construct deep neural networks with novel optimization algorithms (e.g. Adam algorithm or Adagrad algorithm), different kinds of weight initializations (e.g. He's initialization or Xavier initialization), various activation functions (e.g. sigmoidal classification and ReLU activations), new regularization techniques (e.g. dropout), and pre-build complex hidden layers (e.g. convolutional layers). In this Thesis we will focus in deep CNNs, which builds on different parameters: kernel size, pooling, padding and number of filter maps. We will explore the effects of these parameters of convolutional layers as well as other deep learning advances in order to analyse the applicability of deep learning in statistical downscaling.

### III. OBJECTIVES AND WORKPLAN

This Thesis is devoted to the study and application of deep neural networks for statistical downscaling in the context of climate change, building on the intercomparison framework developed in the VALUE initiative [21]. The main objective is developing a CNN-based downscaling method which solves some of the outstanding open problems of statistical downscaling: 1) faces curse of dimensionality and automatically feature select/transform the predictors, 2) exploits the spatial structure, 3) operates over continental-sized domains, 4) is able to extrapolate the results to "unseen" regions by transfer learning and 5) quantifies the uncertainty of the predictions. In order to accomplish this objective we designed the following workplan.

#### A. Complementary academic formation (Months 1 - 6)

The first task to accomplish has been achieving and adequate complementary formation in machine learning and the new advances in deep learning. This has been done using standard texts (e.g. [26], [27]), and attending to special courses and workshops. Moreover, an extensive bibliographic search was conducted in order to get an up-to-date overview of the field, and the published references on machine learning applications to statistical downscaling. From this search we conclude that the topic is yet unexplored (there is a single general publication on this topic, [20]) and, therefore, the

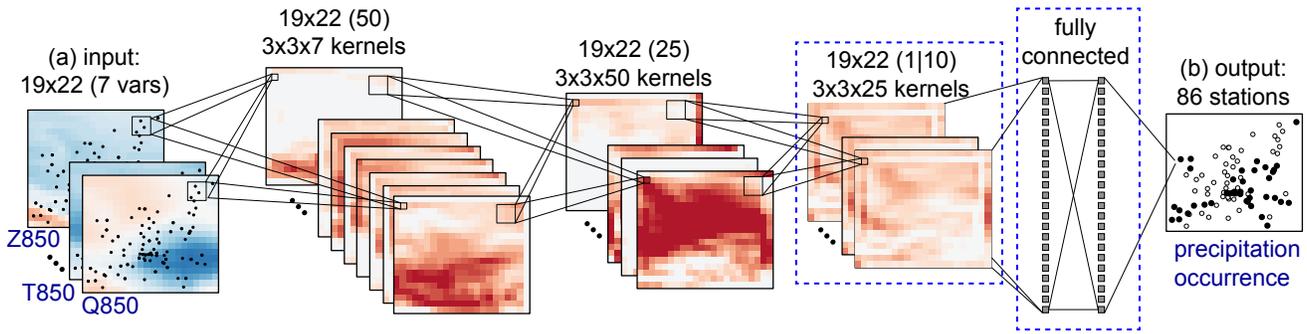


Fig. 2. Deep neural network architecture found in this Thesis to accomplish the objectives proposed. In particular, the net aims to downscale the precipitation's occurrence over 86 stations (output) based on several large-scale predictors of size  $19 \times 22$  (input: 7 predictors), building on three convolutional layers with 50 kernels of size  $3 \times 3 \times 7$ , 25 kernels of size  $3 \times 3 \times 50$  and one kernels of size  $3 \times 3 \times 25$ , respectively, followed by dense layers, with a total of over 50000 parameters. ReLU non-linear functions are used in all layers, except for the outputs, which are sigmoid for classification.

This thesis can be a significant and timely contribution to this field (see Section V).

### B. Deep learning for statistical downscaling (Months 6 - 30)

This task is the core of the Thesis and consists in exploring the deep learning developments in a statistical downscaling context building on TensorFlow. We focus in CNN due to their suitability to deal with spatial inputs (atmospheric fields in this case). However, many different kinds of CNN architectures can be found in the literature, ranging from only convolutional layers to a combination of convolutional, autoencoders and dense layers. Exploring these configurations and understanding its influence on different validation metrics (e.g., temporal and spatial metrics, metrics related to extreme weather events) will be the main topic along the first part of the Thesis. To date we have explored the effects of CNN parameters such as the kernel size, whether to add padding or not (i.e., the filter map has the same resolution than the original map) and whether to incorporate pooling (i.e., a parameter highlighting the presence or not a certain parameter). Furthermore, as we are particularly interested in spatial metrics and the spatial consistency of the climate fields, we pay special attention to multi-task architectures rather than single-task. Thus, during this task we will also evaluate the benefits of multi-task architectures over single-task according to spatial metrics. In the end, the objective will be to come with a particular deep learning net that justifies its architecture based on its ability to handle predictor information and on the benefits obtained from transfer learning. Some first results have been already obtained in this task, corresponding to a simple illustrative classification example (precipitation occurrence, whether it has rained or not) used to analyze and understand the role of the different layers and elements in the downscaling process. This work is described in Section IV, which shows promising results to handle predictor redundancy and irrelevancy automatically.

### C. Quantifying uncertainty (Months 18 - 30)

Bayesian neural networks have existed since the late 80's [28]. However their intractability in many neural network topologies along with a damage in the performance with respect to non-Bayesian neural networks [29], prevented from

a widespread use of these models. Recently, Bayesian deep learning has simplified these problems by simply leaning on dropout [30]. Dropout consists in giving every neuron of the neural net a certain probability to exist in a particular step of the training process. Thus, at every new epoch a new subset of the original net is trained. This randomness generates distributions of predicted values that carry the uncertainty information. Dropout is easily implemented by TensorFlow and will basically consist in adding dropout to the deep learning architecture found to solve SD tasks.

### D. Model Explanation (24 - 30 months)

The climate community is reluctant to black-box machine learning methods due to the inability to explain the results. Therefore, in this Thesis we analyze model explicability of deep learning in statistical downscaling, trying to understand what elements are key for the different components and layers of the model, and which factors influence the performance of the model when compared to benchmark methods. We will examine the physical interpretation (relative to the problem under study) of the different hidden layers. For instance, in Section IV we analyze a simple example that allows for a interpretability of the convolutional layers. Thus, we will try to understand the physics underlying the coupling of large and local scales, as learned by the deep neural network model. For instance, precipitation is driven by different processes in the Mediterranean and in North Europe, but are these physical processes captured as patterns responsible of the improvement of the downscaling with respect to benchmark models?

### E. Divulgarion and contribution to international initiatives (Months 24 - 36)

The results of this Thesis will be published in artificial intelligence and climate journals and conferences, such as Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA), Neural Information Processing Systems (NIPS) and Climate Informatics (CI). In fact, the results described in Section IV have been already submitted to the Climate Informatics congress that will take place in September in Colorado. Moreover, in order to maximize the diffusion and



visibility of this work, (see Section V). Finally, the submission of the Thesis is planned for mid 2020.

#### IV. FIRST RESULTS

In this section we describe the first results obtained during the first year of the realization of the Thesis. We have explored different deep learning topologies and have obtained a particular CNN configuration able to shed light and respond to the objectives described in the previous section for a simple statistical downscaling case-study corresponding to a classification problem: downscaling the occurrence of precipitation. In particular we consider the experimental framework of the first VALUE intercomparison experiment, consisting on downscaling over 86 stations located over Europe (Figure 1). As benchmark we use one of the best performing models participating in this experiment, based on Generalized Linear Models (GLM), in particular logistic regression for this case [6].

The topology of deep learning architectures vary depending on the task to be solved. According to the objectives described in Section III, the configuration for this problem should automatically handle the selection of predictors, dealing with the typical redundancy and irrelevancy properties of atmospheric predictors. In particular to this study we have used the following redundant set: the specific humidity at 850 and 700 hPa, the temperature at 850 and 700 hPa, and the geopotential height at 1000, 850 and 500 hPa. In order to address the latter and find an adequate configuration, we have tested a combination of convolutional layers with dense layers (see Figure 2). The output layer has 86 neurons, one for each station of Figure 1. For this case-study, an only-convolutional configuration (i.e., excluding the two last fully connected layers) achieves higher validation scores and provides more interpretability with respect to unraveling the implicit geographical feature selection for this simple example. However, the search has not been limited to define whether the net should be partially or totally convolutional, and the number of filter maps in the last layer has been found to be crucial for the performance. Performance suffers from the curse of dimensionality and thus the addition of unnecessary filter maps to the neural architecture harms the statistical significance of the model. This is specially relevant if they are added in the last layer directly having an impact in the space's size where there is the boundary layer separating rainy from non-rainy days. As a consequence, reducing the number of filter maps to 1 in the last layer has shown better performance than with a bigger number of filter maps (e.g., 10), demonstrating that only 1 filter map is necessary to this simple case. In this only 1 filter map architecture, the CNN filters the information coming from the original predictors retaining a pattern that best downscales the precipitation and representing it spatially in its third layer, generating a new novel super-predictor. By this way, the CNN feature selects/transforms the original predictors into only 1. But does CNN also performs a domain feature-selection?. In Figure 3 we observe the coefficient's values linking the third layer with the output layer for a) Madrid and b) Helsinki.

It is interesting that the CNN automatically finds the area influencing the local climate for a particular station, from its surrounding geographical region, ignoring the rest of the continental domain.

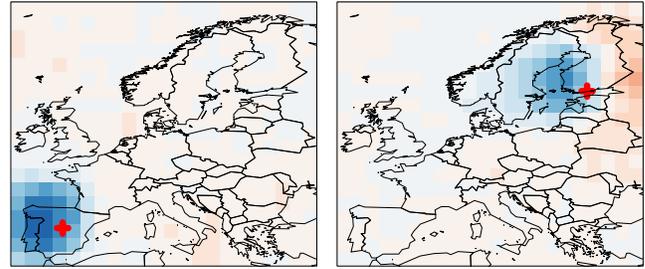


Fig. 3. Weights from the last convolution layer to the outputs (the stations) for Madrid (left) and Helsinki (right). A  $5 \times 5$  spatial moving average is applied to represent the effect of kernels. Blue/red colors indicate positive/negative weights.

The resulting CNN shows better performance than the considered state-of-the-art benchmark method (GLM), in terms of a standard validation measure: Relative Operating Characteristics Skill Score (ROCSS), which is a standard accuracy measure for probabilistic predictions of binary variables. In Figure 4 we observe the ROCSS as a function of the a) training epochs and b) stations for three different configurations of deep learning models and for the benchmark (GLM). We observe how the deep CNN with only 1 feature map in its last layer and with no fully connected layers after the convolutions achieves the best results. In particular, it is remarkable how deep learning models have achieved considerably higher results than the benchmark model, which additionally required a tedious pre-analysis of the predictors.

#### V. RELEVANCE

Statistical downscaling is an important problem in the context of climate change, since it allows to transfer the global information of GCMs to the regional and local scales needed in impact studies. There are a number of important international initiatives which focus on this problem, including the IPCC (Intergovernmental Panel on Climate Change, [4]) and CORDEX (COordinated Regional climate Downscaling Experiment, [22]). Also, at a national level, the Spanish National Adaptation Plan (PNACC) provides regional climate change information for Spain building, among others, on statistical downscaling methods (see <http://escenarios.adaptecca.es>). At an international level, one of the main limitations of statistical downscaling method is that they need to be applied at a global level, considering continental domains. As we have seen in the previous sections, state-of-the-art statistical downscaling methods cannot operate automatically and require human intervention to define suitable geographical regions, predictors, etc. CNNs may provide an alternative to circumvent these problems and may contribute to these initiatives providing downscaled results with global coverage. The Thesis will be performed in the framework of these initiatives, which will serve as ideal platforms for the dissemination of results. At

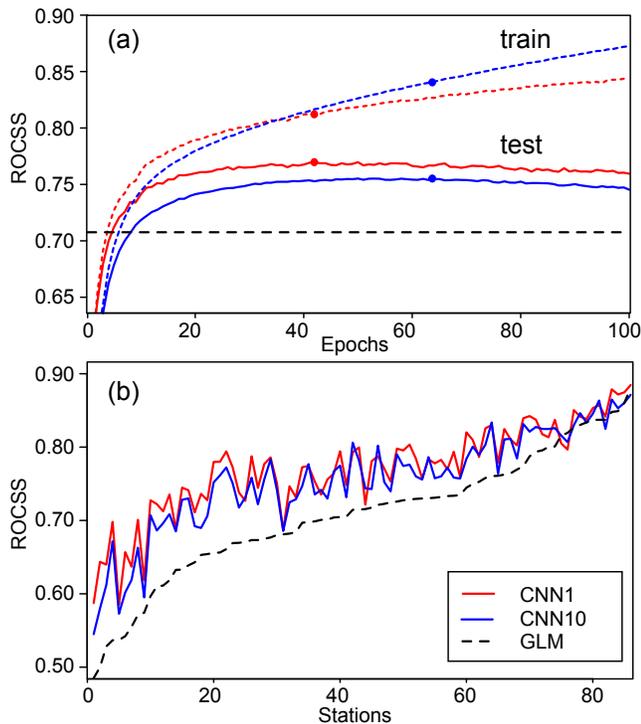


Fig. 4. Results (ROCSS) of the different downscaling models as a function of (a) the epochs (train/test results are indicated by solid/dashed lines; the dots indicate early stopping) and (b) the stations for the trained models, with stations sorted according to the GLM results. The deep learning models have 1 filter map in the third hidden layer (CNN1) or 10 filter maps (CNN10).

a national level, one of the main limitations of statistical downscaling methods is that they do not provide spatially consistent results. CNNs could also circumvent this problem, thus contributing to a better provision of regional climate change information for impact studies in Spain.

#### ACKNOWLEDGMENTS

Funding was provided by the project MULTI-SDM (CGL2015-66583-R, MINECO/FEDER).

#### REFERENCES

- [1] D. Maraun and M. Widmann, *Statistical Downscaling and Bias Correction for Climate Research*. Cambridge University Press, 2018.
- [2] M. Gaertner, J. M. Gutierrez, and M. Castro, "Escenarios regionales de cambio climático," vol. 26, no. 2.
- [3] IPCC, *Summary for Policymakers*, book section SPM, p. 130. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press, 2013.
- [4] M. Collins, R. Knutti, J. Arblaster, J.-L. Dufresne, T. Fichefet, P. Friedlingstein, X. Gao, W. Gutowski, T. Johns, G. Krinner, M. Shongwe, C. Tebaldi, A. Weaver, and M. Wehner, *Long-term Climate Change: Projections, Commitments and Irreversibility*, book section 12, p. 10291136. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press, 2013.
- [5] J. T. Schoof, "Statistical downscaling in climatology," vol. 7, no. 4, pp. 249–265.
- [6] J. M. Gutierrez, D. Maraun, M. Widmann, R. Huth, E. Hertig, R. Benestad, O. Roessler, J. Wibig, R. Wilcke, S. Kotlarski, D. San Martin, S. Herrera, J. Bedia, A. Casanueva, R. Manzananas, M. Iturbide, M. Vrac, M. Dubrovsky, J. Ribalaygua, J. Prtoles, O. Rty, J. Risnen, B. Hingray, D. Raynaud, M. J. Casado, P. Ramos, T. Zerrenner, M. Turco, T. Bosshard, P. tpnek, J. Bartholy, R. Pongracz, D. E. Keller, A. M. Fischer, R. M. Cardoso, P. M. M. Soares, B. Czernecki, and C. Pag, "An

- intercomparison of a large ensemble of statistical downscaling methods over Europe: Results from the VALUE perfect predictor cross-validation experiment," *International Journal of Climatology*, Mar. 2018.
- [7] R. L. Wilby, T. M. L. Wigley, D. Conway, P. D. Jones, B. C. Hewitson, J. Main, and D. S. Wilks, "Statistical downscaling of general circulation model output: A comparison of methods," vol. 34, no. 11, pp. 2995–3008.
- [8] J. Schoof and S. Pryor, "Downscaling temperature and precipitation: a comparison of regression-based methods and artificial neural networks," vol. 21, no. 7, pp. 773–790.
- [9] S. Tripathi, V. V. Srinivas, and R. S. Nanjundiah, "Downscaling of precipitation for climate change scenarios: A support vector machine approach," vol. 330, no. 3, pp. 621–640.
- [10] S. H. Pour, S. Shahid, and E.-S. Chung, "A hybrid model for statistical downscaling of daily rainfall," vol. 154, pp. 1424–1430.
- [11] X. He, N. W. Chaney, M. Schleiss, and J. Sheffield, "Spatial downscaling of precipitation using adaptable random forests," vol. 52, no. 10, pp. 8217–8237.
- [12] S.-T. Chen, P.-S. Yu, and Y.-H. Tang, "Statistical downscaling of daily precipitation using support vector machines and multivariate analysis," vol. 385, no. 1, pp. 13–22.
- [13] T. Vandal, E. Kodra, and A. R. Ganguly, "Intercomparison of machine learning methods for statistical downscaling: The case of daily and extreme precipitation,"
- [14] C. Yang, N. Wang, S. Wang, and L. Zhou, "Performance comparison of three predictor selection methods for statistical downscaling of daily precipitation," pp. 1–12.
- [15] J. Schmidhuber, "Deep learning in neural networks: An overview," vol. 61, pp. 85–117.
- [16] Y. LeCun and Y. Bengio, "Convolutional networks for images, speech, and time series," *The handbook of brain theory and neural networks*, vol. 3361, no. 10, p. 1995, 1995.
- [17] S. Min, B. Lee, and S. Yoon, "Deep Learning in Bioinformatics," p. 46.
- [18] R. Pradhan, R. S. Aygun, M. Maskey, R. Ramachandran, and D. J. Cecil, "Tropical Cyclone Intensity Estimation Using a Deep Convolutional Neural Network," *IEEE Transactions on Image Processing*, vol. 27, pp. 692–702, Feb. 2018.
- [19] Y. Liu, E. Racah, Prabhat, J. Correa, A. Khosrowshahi, D. Lavers, K. Kunkel, M. Wehner, and W. Collins, "Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets," *arXiv:1605.01156 [cs]*, May 2016. arXiv: 1605.01156.
- [20] T. Vandal, E. Kodra, S. Ganguly, A. Michaelis, R. Nemani, and A. R. Ganguly, "DeepSD: Generating High Resolution Climate Change Projections through Single Image Super-Resolution," Mar. 2017.
- [21] D. Maraun, M. Widmann, J. M. Gutierrez, S. Kotlarski, R. E. Chandler, E. Hertig, J. Wibig, R. Huth, and R. A. Wilcke, "VALUE: A framework to validate downscaling approaches for climate change studies," vol. 3, no. 1, p. 2014EF000259.
- [22] W. J. Gutowski Jr., F. Giorgi, B. Timbal, A. Frigon, D. Jacob, H.-S. Kang, K. Raghavan, B. Lee, C. Lennard, G. Nikulin, E. O'Rourke, M. Rixen, S. Solman, T. Stephenson, and F. Tangang, "WCRP CO-ordinated regional downscaling EXperiment (CORDEX): a diagnostic MIP for CMIP6," vol. 9, no. 11, pp. 4087–4095.
- [23] S. Ruder, "An Overview of Multi-Task Learning in Deep Neural Networks," *arXiv:1706.05098 [cs, stat]*, June 2017. arXiv: 1706.05098.
- [24] R. Collobert and J. Weston, "A Unied Architecture for Natural Language Processing: Deep Neural Networks with Multitask Learning," p. 8.
- [25] R. Girshick, "Fast R-CNN," pp. 1440–1448, 2015.
- [26] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag, 2006.
- [27] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [28] N. Tishby, E. Levin, and S. A. Solla, "Consistent inference of probabilities in layered networks: predictions and generalizations," in *International 1989 Joint Conference on Neural Networks*, pp. 403–409 vol.2, 1989.
- [29] G. E. Hinton, "Keeping Neural Networks Simple by Minimizing the Description Length of the Weights," p. 9.
- [30] Y. Gal, "Uncertainty in Deep Learning," p. 166.

# Cost-effective Techniques for Patient Positioning in Percutaneous Radiotherapy Using Optical Imaging Systems

Hamid Sarmadi  
Artificial Vision Applications Group  
IMIBIC  
Córdoba, Spain  
hamid.sarmadi@imibic.org

**Abstract**—Patient positioning is an important task in radiation therapy that prevents healthy tissue to be radiated with dangerous electromagnetic waves. There are already different systems that assist precise patient positioning however they expose the patient to extra radiations, are not accurate enough, or are too expensive for the average hospital in Spain. In this thesis we want to verify the possibility of creating a system based on recently developed computer vision algorithms and RGBD sensors that is affordable and at the same time accurate for the purpose of patient positioning.

**Keywords**—radiotherapy; radiation therapy; computer vision; depth sensor; rgbd sensor; patient positioning; pose estimation

## I. THESIS INFORMATION

Contact Information:  
hamid.sarmadi@imibic.org

Thesis Directors:  
Rafael Muñoz-Salinas, Rafael Medina-Carnicer

University Department:  
Departamento de Informática y Análisis Numérico  
Universidad de Córdoba  
Córdoba, Spain

Starting Date:  
April 2017

## II. SUMMARY AND RELEVANCE

Percutaneous radiotherapy is done by focusing an electromagnetic wave at the tumor or the target tissue in the body. It has two main phases. First, the planning phase in which normally a CT scan, PET scan or MRI are done to determine the exact position of the target tissue in the patient's body and acquiring a 3D model. Second, the treatment phase, where there are normally multiple sessions and in each one the patient needs to be positioned in the exact same pose in which the initial scans are done. Then with the help of the initial scans the exact position of the target area in the body is determined and is treated with an electromagnetic beam.

There could always be errors in positioning the patient in the exact pose as in the initial scan and that there also could be movements in the internal organs. These can cause the radiation of healthy tissue in radiation therapy which begs for accurate validation systems for patient positioning. Furthermore, recently, new methods such as intensity modulated radiation therapy (IMRT) that can achieve high precision and volumetric modulated arc therapy (VMAT) which can reduce the time of radiation have been created that put extra reliance on precise positioning of the patient.

There are already high precision patient positioning methods. One example works using X-ray imaging to determine the bone structure at the time of treatment in two dimensions. Then the digitally reconstructed radiograph (DRR) from CT scans obtained in the planning phase are manually aligned with the 2D X-ray image to estimate the position of the tumor [6]. This method however puts the patient under extra radiation for each session of the therapy and is not very accurate. Another X-ray based approach is computed tomography cone beam (CBCT). This method is more accurate since it creates a 3D reconstruction of the bone structure by rotating a cone beam around the patient and combining its images. The 3D bone reconstruction then is compared to the CT scan. Though more accurate, the method still uses X-ray which puts healthy tissue under dangerous radiation. Further more it has a high cost.

Other radiation-less methods have been introduced. In [7] a method based on orthogonal video sequences is proposed. The videos are aligned with reference images to estimate the pose. This technique has been used for the treatment of head and neck area [8]. In another type of approach reflective markers in conjunction with infrared cameras have been utilized [9]. Reflective markers are placed in pre-known positions on the patient's body and multiple infrared cameras are used to determine the 3D position of each marker and hence estimate the pose of the patient. However, this technique can only estimate the pose of the markers and not the whole surface of the body. In more recent years, 3D reconstruction has gained more popularity. One method is to project a beam of laser on the patient's body and using the images taken with calibrated cameras reconstruct the 3D surface of the body. This has been applied for rectal cancer [10] prostate cancer [11] patients. By projecting 2D random patterns instead of a one-dimensional beam [12] it is possible to have a real-time 3D reconstruction of the patient's position. This system can also be used to give the patient feedback regarding the accuracy of their position during

the radiation therapy [1]. This type of method could obtain a high precision [2].

More specifically CATALYST [1,2] and ALIGNRT [3] are two industrial level approaches where the visual 3D scan of the patient is matched with the CT scan done in the planning phase for verification of the patient's position. These methods, however, have a high cost for the average hospital in Spain.

On the other hand, in the field of computer vision, improvements have been done in human pose estimation using a single view (monocular) or multiple cameras. M. J. Marín-Jiménez from our group has published multiple methods for monocular human pose estimation in collaboration with Oxford University and ETH Zurich [13-15]. These methods are based on appearance based detectors and pictorial structures [16] probabilistic model of human poses. There are also multi-view approaches. One variance of them is to extend single view methods to multiple cameras and use the extra 3D information to improve the pose estimation. There have been publications from our group also in this area [17,18]. In [5] the pictorial structures is extended to three dimensions and random forest based detectors have been used as fast appearance models. They can obtain good results in pose estimation of football players. Marker-less motion capture algorithms are another class of methods that work based on a pre-known model of the subject to be tracked [19,20]. Our group has also experience in the field of marker-less motion capture [21,22]. Most recently over the counter depth cameras have been used for the purpose of 3D human pose estimation [23]. These are similar to the already mentioned CATALYST and ALIGNRT systems with the difference that they utilize projected patterns with visible light whereas normally depth cameras such as Microsoft Kinect use the infrared light hence they would not pose limitations on environment lighting for example in the radiation therapy treatment room.

In this thesis, we intend to verify the possibility of obtaining an affordable visual based patient positioning system that combines advanced computer vision approaches with consumer level depth sensors and cameras with acceptable precision. Our hypothesis is that we can use recent advances in computer vision algorithms in the fields of 3D reconstruction and human pose estimation combined with recently commercialized affordable sensors to create a patient positioning system for radiation therapy. The current technologies do not use the latest algorithms and are also expensive. We suspect that it is possible to create an affordable patient positioning system with our approach to the problem. More precisely our goals in this thesis are:

- 1- Designing a portable computer vision based portable patient positioning system for radiation therapy.
- 2- Incorporating 3D reconstruction algorithms in conjunction with the new affordable consumer level 3D sensors in the system.
- 3- Employing human pose estimation and/or marker-less motion capture algorithms to help determine the precise position of the target.

#### A. *Designing a portable computer vision based portable patient positioning system*

Radiation therapy room normally have ceilings where it is possible to install specialized equipment and wiring. In systems such as CATALYST and ALIGNRT the 3D scanners need to be installed in special positions on the ceiling so that they do

not interfere with other equipment. Even after installation they need to be calibrated in a slow process by a specialized person.

We intend to design a system that could be easily installed and detached from the room and could be calibrated quickly and easily. This will facilitate moving the system from one hospital to another hospital, and reduce the installation and maintenance costs.

We would use affordable consumer level 3D cameras similar to Microsoft Kinect that in addition to being a 3D scanner provide us with high resolution color images which could help significantly in the task of 3D reconstruction and pose estimation compared to using only depth sensors. Furthermore such cameras make it possible to calibrate the system in a short amount of time. In our group, a fast calibration algorithm using fiducial planar markers has been already developed [4] and is included in the well-known OpenCV computer vision library. We would use the same type of fiducial markers and attach them to the stretcher where the patient is positioned, visible to the cameras for the purpose of fast calibration.

#### B. *Incorporating 3D reconstruction algorithms in conjunction with the new affordable consumer level 3D sensors*

In the past few years after the release of the initial Kinect sensor, which is the combination of a color digital camera and a depth sensor i.e. RGB-D, new computer vision algorithms have been developed for 3D reconstruction that take advantage of the depth data or both depth and image data at the same time, notably starting with the KinectFusion algorithm. While there have been a lot of improvements in these algorithms for different types of scenes the accuracy of reconstruction is still not as good for raw usage in our patient positioning system. We would like to get help from the visual information that comes from the color camera and other techniques to improve upon the existing algorithms and make a 3D reconstruction system that is fast but also accurate and suitable for the application we have in mind.

#### C. *Employing human pose estimation and/or marker-less motion capture algorithms to help determine the precise position of the target*

Pictorial Structures is one of the most successful human pose estimation algorithms that is normally used in single view scenarios. However, this method is normally useful for pose estimation of humans that are standing. Recently, there have been developments in expanding this algorithm to combine information from multi-views [5]. Our group has experience with this type of algorithm.

Additionally we intend to build upon the current human motion capture algorithms that is developed in our group. We would extend them by incorporating the extra 3D information that we get from the sensors. This technique requires a model of the human to start its tracking. Using the 3D model that could be obtained from the initial scan in the planning phase of the treatment (e.g. CT scan, MRI, etc.) can help the motion capture algorithm significantly.

Normally, marker-less motion capture systems rely on inferring 3D information from the multiple view normal cameras. We think that we can improve the algorithm by additionally taking advantage of the depth information from the RGB-D sensors, in both initialization of the pose and tracking

of the pose. More specifically in the tracking phase, it would be possible to track non-rigid deformations of the body accurately with the help of the depth sensor. For example, consider the up and down movement of the chest that happens with respiration. It would be of high advantage for accuracy if we were able to track the deformable surface of the chest.

### III. METHODOLOGY AND WORK PLAN

#### A. Designing a Portable Imaging system

The first step in doing the thesis is to design a self calibrating imaging system that could be easily ported and is sufficiently accurate at the same time. In the past few years depth sensors that take advantage of structured active lighting to estimate a distance image for the devices have been commercialized for the purpose of entertainment (e.g. Microsoft Kinect) and research. These are affordable devices that normally project an infrared random pattern on the environment and calculate the depth for the pixels of their infrared camera by triangulation. Not using visible light - unlike what is done in CATALYST and ALIGNRT - removes the need for special considerations with regard to lighting of the indoor environment. Furthermore, easy calibration procedure removes the need of specialized personnel for installation and facilitates transferring the system between rooms or other hospitals.

For this purpose we have done a research for automatic pose estimation and calibration of a multi-camera system with respect to a set of ArUco markers. ArUco markers are visual planar fiducial markers that can be easily attached to flat surfaces and work as a reference in the 3D environment. This system is able to estimate the pose of the ArUco markers with respect to each other, estimate the relative pose of the cameras with respect to each other and also track the relative pose

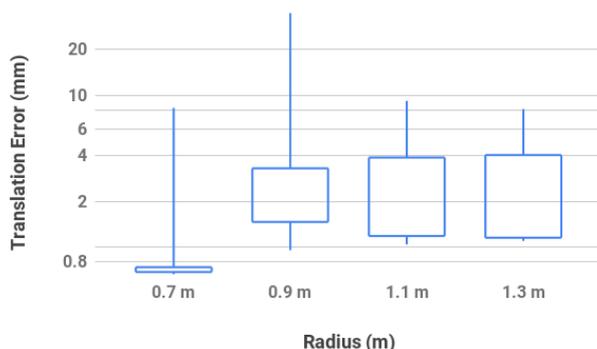


Figure 1: Error in estimation of relative position between the cameras and the markers using 3 cameras.

between the marker and cameras at each frame all at the same time. In this work we were able to reach sub-millimeter accuracy in estimating the relative pose between the cameras (which are fixed relative to each other) and the set of markers (which are also fixed with respect to each other). This is despite the fact that we used low resolution color cameras and we did not even use depth sensors. This was a promising milestone in this phase of thesis. You can see some of our results in Fig. 1 where we used 3 cameras in a circle configuration and the markers were attached to an object in the middle of the circle.

The next milestone in this phase would be employing the RGB-D sensors taking into account both depth and color image

for estimating the 3D surface of the patient. We are intending to design an algorithm that could effectively combine the dense information that comes from the depth cameras with sparse information that comes from planar markers or feature points in the color camera for accurate tracking of the cameras and reconstruction of patient's body surface.

#### B. Incorporating Human Pose Estimation

The second phase of this thesis would be to use the accurate imaging system that is designed in the first phase and give its output to a human pose estimation system. Human pose estimation can determine the skeletal pose of the patient from the color image or the depth image. In order to be able to estimate the human pose accurately we need to adapt existing algorithms so that they can take our surface reconstruction as input. We are not aware of any system in patient positioning that incorporates human pose estimation.

The first milestone in this phase is a human pose estimator that could possibly take a model of the patient as input for higher accuracy pose estimation and use the surface reconstruction from the previous phase for a precise human pose estimation.

After that we need to use the information from our pose estimator and combine it with the 3D model from patient's CT scan. This is needed to model patient's inside organs and predict their position in the 3D space. Therefore, second milestone in this phase would be high accuracy boundary estimation of the area in the body that needs to be treated with radiation therapy.

### REFERENCES

- [1] D. J. D'Ambrosio, J. Bayouth, I. J. Chetty, M. K. Buyyounouski, R. A. Price Jr, C. R. Correa, T. J. Dilling, G. E. Franklin, P. Xia, E. E.R. Harris, A. Konski, "Continuous localization technologies for radiotherapy delivery: Report of the American Society for Radiation Oncology Emerging Technology Committee," *Practical Radiation Oncology*, 2:145-150, 2012
- [2] P.J. Schöffel, W. Harms, G. Sroka-Perez, W. Schlegel, C.P. Karger, "Accuracy of a commercial optical 3D surface imaging system for realignment of patients for radiotherapy of the thorax," *Phys Med Biol*, 52:3949-3963, 2007
- [3] F. Walter, P. Freisleder, C. Belka, C. Heinz, M. Söhn and F. Roeder, "Evaluation of daily patient positioning for radiotherapy with a commercial 3D surface-imaging system (Catalyst™)," *Radiation Oncology*, 11:154, 2016
- [4] S. Garrido-Jurado, R. Muñoz-Salinas, F. J. Madrid-Cuevas, M. J. Marín-Jiménez "Automatic generation and detection of highly reliable fiducial markers under occlusion," *Pattern Recognition*, 47(6):2280-2292, 2014
- [5] V. Kazemi, M. Burenius, H. Azizpour, and J. Sullivan. "Multi-view Body Part Recognition with Random Forests," *BMVC 2013*
- [6] S. Yoshino, K Miki, K Sakata, Y Nakayama, K Shibayama, S. Mori, "Digital reconstructed radiography with multiple color image overlay for image-guided radiotherapy," *Journal of Radiation Research*, 56(3):588-593, 2015
- [7] L.S. Johnson, B.D. Milliken, S.W. Hadley, et al., "Initial clinical experience with a video-based patient positioning system," *Int J Radiat Oncol Biol Phys*, 45:205-213, 1999
- [8] B.D. Millikin, S.J. Rubin, R.J. Hamilton, et al., "Performance of a video-image-subtraction-based patient positioning system," *Int J Radiat Oncol Biol Phys*, 38:855-866, 1997

- [9] G. Baroni, G. Ferrigno, R. Orecchia, et al., "Real-time three-dimensional motion analysis for patient positioning verification," *Radiother Oncol*, 54:21–27, 2000
- [10] C. Moore, F. Lilley, V. Sauret, et al., "Opto-electronic sensing of body surface topology changes during radiotherapy for rectal cancer," *Int J Radiat Oncol Biol Phys*, 56:248–258, 2003
- [11] R.I. MacKay, P.A. Graham, J.P. Logue, et al., "Patient positioning using detailed three-dimensional surface data for patients undergoing conformal radiation therapy for carcinoma of the prostate: A feasibility study" *Int J Radiat Oncol Biol Phys*, 49:225-230, 2001
- [12] J.P. Siebert, S.J. Marshall, "Human body 3D imaging by speckle texture projection photogrammetry," 20:218-226, 2000
- [13] M. Eichner, M. J. Marín-Jiménez, A. Zisserman, V. Ferrari, "2D Articulated Human Pose Estimation and Retrieval in (Almost) Unconstrained Still Images" *International Journal of Computer Vision* 99(2): 190-214 (2012)
- [14] V. Ferrari, M. J. Marín-Jiménez, A. Zisserman, "Progressive search space reduction for human pose estimation" *CVPR* 2008
- [15] V. Ferrari, M. J. Marín-Jiménez, A. Zisserman, "Pose search: Retrieving people using their pose," *CVPR* 2009
- [16] P. Felzenszwalb, D. Huttenlocher. "Pictorial Structures for Object Recognition," *International Journal of Computer Vision* 61(1): 55-79, 2005
- [17] R. Muñoz-Salinas, R. Medina-Carnicer, F.J. Madrid-Cuevas, A. Carmona-Poyato, "Particle filtering with multiple and heterogeneous cameras," *Pattern Recognition*, 43 (7): 2390-2405, 2010
- [18] R. Muñoz-Salinas, "A Bayesian plan-view map based approach for multiple-person detection and tracking," *Pattern Recognition*, 41 (12), 3665-3676, 2008
- [19] J. Bandouch, F. Engstler and M. Beetz, "Accurate Human Motion Capture Using an Ergonomics-Based Anthropometric Human Model," *Lecture Notes In Computer Science*, 5098: 248 – 258, 2008
- [20] A. Sundaresan and R. Chellappa, "Model Driven Segmentation of Articulating Humans in Laplacian Eigenspace," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30: 1771-1785, 2008
- [21] E. Yeguas-Bolivar, R. Muñoz-Salinas, R. Medina-Carnicer, A. Carmona-Poyato, "Comparing evolutionary algorithms and particle filters for Markerless Human Motion Capture," *Applied Soft Computing*, 17:153-166, 2014
- [22] A. Cano, E. Yeguas-Bolivar, R. Muñoz-Salinas, R. Medina-Carnicer, S. Ventura, "Parallelization strategies for markerless human motion capture," *Journal of Real-Time Image Processing*, 17:1-15, 2014
- [23] M. Stommel, M. Beetz, W. Xu, "Model-free detection, encoding, retrieval, and visualization of human poses from kinect data," *IEEE/ASME Transactions on Mechatronics*, 20 (2): 865-875, 2015



# Modelo de evaluación de la usabilidad de entornos web basado en las metodologías de computing with words y design thinking. Caso de uso en entornos virtuales de aprendizaje

Noe Zermeño\*, Rosana Montes\* and Francisco Herrera\*

\*Andalusian Research Institute on Data Science and Computational Intelligence, DaSCI

Universidad de Granada, Granada, Spain

Emails: nzermeno@correo.ugr.es, rosana@ugr.es, herrera@decsai.ugr.es

**Abstract**—Con el incremento en el uso de internet, diversos servicios están haciendo uso de la nube, tal es el caso de la difusión de información, contratación o venta de productos y servicios, además de plataformas de gestión para el aprendizaje en línea. Es necesario crear sistemas informáticos que garanticen el acceso total del contenido digital para cubrir las necesidades del colectivo de personas, independientemente de las capacidades o discapacidades con las que ellas cuenten. La evaluación de los sistemas informáticos mediante estándares dictados por el *World Wide Web Consortium (W3C)* implica la selección de una herramienta de validación del nivel de accesibilidad. Al existir una vasta cantidad de herramientas se debe considerar aquella que satisfaga un conjunto de criterios determinados por los administradores de los *Learning Management System (LMS)*, esto para garantizar el acceso a la información. Así mismo, la usabilidad se puede evaluar a través de técnicas que midan la interacción persona-ordenador (HCI, por sus siglas en inglés). Por lo tanto, se incorpora *Design Thinking* que es una disciplina que centra las necesidades del usuario en el diseño del sistema informático. Debido a que para los humanos es más sencillo ofrecer su opinión en lenguaje natural, se incorporan procesos de computación con palabras. La utilización de modelos de representación lingüística como *Intuitionistic Fuzzy Sets* y *2-Tuple Linguistic* permite la obtención y agregación de las opiniones, resultando una etiqueta lingüística con el grado de usabilidad y accesibilidad de sistema evaluado.

## I. INTRODUCCIÓN

Para poder evaluar los sistemas de información, es preciso utilizar alguna metodología como lo es la Interacción Persona-Ordenador (HCI, por sus siglas en inglés). HCI engloba cuatro disciplinas: el Graphic Interface User (GUI), el Interaction Design (IXD), la Usabilidad y Experiencia del Usuario (UX, por sus siglas en inglés).

Derivado de GUI, se encuentra *Design Thinking (DT)*. DT es una disciplina usada actualmente para procesos de innovación y emprendimiento debido a que centra su eficacia en entender y solucionar a las necesidades de los usuarios. Además DT incorpora UX, que evalúa la percepción positiva o negativa entre la interacción de los usuarios con determinados servicios, productos o dispositivos [1].

Se evalúa la usabilidad del sistema software, que es la medida en la que el sistema se puede usar por determinados

usuarios para conseguir objetivos específicos con efectividad, eficiencia y satisfacción en un contexto de uso especificado [2]. Determinar en qué medida un sistema informático como las páginas web o los *Learning Management System (LMS)* son usables se ha convertido en prioritario para empresas, por lo que la evaluación de los sistemas debe centrarse principalmente en las necesidades de los usuarios en términos de usabilidad y accesibilidad.

Puesto que la usabilidad abarca la accesibilidad, nos interesa evaluar la primera. Existen diversas técnicas para la evaluación de la usabilidad, entre este conjunto se hace uso de: (1) Indagación (*Checklist*), (2) Inspección (*FocusGroup*, *Questionarios*) y (3) Test (*Medidas de Rendimiento*). Cabe destacar que la técnica más utilizada actualmente como instrumento de recogida de datos, por coste y facilidad, son los cuestionarios. Además existen instrumentos estándares en la evaluación de la satisfacción del usuario tales como: *Questionnaire for User Interface Satisfaction (QUIS)* [3], *Software Usability Measurement Inventory (SUMI)* [4], *Website Analysis and Measurement Inventory (WAMMI) Questionnaire* [5], *Scale Usability System (SUS)* [6] y *Net Promoter Score (NPS)* [7].

Los atributos de la usabilidad tales como: aprendizaje, eficiencia, memorabilidad, manejo de errores y satisfacción, se enfocan en las apreciaciones de tienen los usuarios ante los sistemas, por lo tanto se requiere de instrumentos específicos que recolecten opiniones subjetivas y/o lingüísticas.

## II. HIPÓTESIS DE PARTIDA

Existen trabajos que evalúan la usabilidad de los sistemas de información desde diferentes dimensiones [8], [9]. Las evaluaciones se realizarán a través de escalas binarias y Likert.

Nuestra propuesta parte del supuesto de la mejora en la interpretabilidad de las opiniones sobre la evaluación de la usabilidad de los sistemas web mediante la toma de decisiones utilizando procesos de Computing with Words y modelos lingüísticos.

Existen otros instrumentos basados en enfoques lingüísticos tales como Computing with Words (CW) [10]–[12] que permiten la evaluación de las opiniones de los usuarios por medio

de procesos CW. Al hacer uso de parabras o expresiones lingüísticas compuestas, permiten expresar información vaga e imprecisa con mayor flexibilidad que los números [13]. El uso de enfoques lingüísticos es ampliamente usado en modelos de decisión que se asemejan al de la naturaleza humana y que facilitan el proceso de toma de decisiones. *Multi Expert Multi Criteria Linguistic Decision Making* (MEMCLDM), puede ser empleado para evaluar un conjunto de alternativas con diversos criterios utilizando variables lingüísticas [14]–[17].

Para evaluar la usabilidad hay que conocer las necesidades de todos los usuarios (Diseño Universal del Aprendizaje/DT). Además se debe considerar qué tareas producen emociones negativas y por tanto valoraciones pobres de la usabilidad. Dilucidar la usabilidad de un LMS se hace con el fin de mejorar el sistema, o simplemente de obtener un ranking de LMS. Por ejemplo un A/B testing que emplee el modelo propuesto puede conocer si la activación de un plugin mejora o empeora la usabilidad del sitio atendiendo a la opinión de sus propios usuarios.

### III. OBJETIVO GENERAL

El objetivo de este trabajo de investigación es desarrollar un modelo lingüístico de toma de decisiones para la evaluación de la usabilidad con soporte en software con licencia libre. Su aplicación facilitará procesos de evaluación de la usabilidad y accesibilidad de Moodle 2.x y 3.x, por medio de información cualitativa y cuantitativa en contextos heterogéneos.

#### 1) *Objetivos específicos:*

- 1) Determinar los factores de accesibilidad de sistema web.
- 2) Resolver el problema MEMCLDM mediante procesos de CW al combinar técnicas de inspección, indagación, test para la evaluación de usabilidad y evaluación del nivel de accesibilidad.
- 3) Desarrollar un software que aplique el modelo lingüístico de evaluación de usabilidad y accesibilidad en Moodle 2.x y 3.x.

### IV. METODOLOGÍA Y PLAN DE TRABAJO

La presente investigación aborda problema MEMCLDM a través de un enfoque de CW. El análisis y desarrollo se hace mediante DT y la representación lingüística de 2-tuplas para la resolución del MEMCLDM con información vaga e imprecisa mediante etiquetas lingüísticas.

Esta investigación cuenta con un enfoque mixto:

- **Cualitativo:** datos resultantes de test usabilidad, NPS y evaluación de accesibilidad web.
- **Cuantitativo:** obtenidos a través de Checklist que se aplican a Focus Group y cuestionario SUS.

La metodología se inicia con un análisis teórico–metodológico de los proyectos de investigación sobre evaluaciones de usabilidad en las bases de datos principales (Scopus y Web of Science). Se analizan y discriminan las investigaciones sobre usabilidad y accesibilidad en sistemas web y se acotan los resultados a aquellos que trabajan con problemas multicriterio.

- **Fase Comprender, Observar:** Esta fase se realiza con la utilización de la técnica Focus Group en la Universidad de Guadalajara (UdG) en Guadalajara, Jalisco, México, donde la actividad es mediante la realización de actividades en Moodle<sup>1</sup> definidas en un primer Checklist. Estas actividades serán realizadas por diferentes tipos de usuarios lo cuales se diversifican desde la técnica role playing. Para medir la tasa de éxito, pensamientos y satisfacción de los usuarios ante la realización de estas actividades se usan técnicas tales como:

- 1) *Feedback Capture Grid (FCG):* Se utiliza para facilitar la captura en tiempo real de la retroalimentación de cada momento en los que se anticipa la interacción entre el presentador y el crítico. Ayuda a ser sistemático sobre la retroalimentación, y más intencional sobre la captura de pensamientos en los cuatro diferentes sectores.
- 2) *Customer Journey Map (CJM):* Es una herramienta de DT que nos permite mostrar en un mapa cada una de las fases, interacciones, vías y elementos por los que pasa el usuario de un punto a otro de la actividad.

Se considera la técnica de rol playing involucrando 3 dados: (1) características con las que cuentan los usuarios que hacen uso de los LMS; (2) necesidades para acceder correcta y totalmente a la información y (3) emociones en el que el usuario se encuentra al momento de utilizar un sistema, con la finalidad de abarcar una diversidad de usuarios formando una 4-tupla (tipo, necesidad, emoción, valoración).

- **Fase Definir:** En esta fase se determina la herramienta de evaluación de accesibilidad a través de valoraciones de expertos utilizando procesos de CW y Conjuntos Intuicionistas Difusos (IFS, por sus siglas en inglés) propuestos por Atanassov en 1986 [18]. Estas herramienta de evaluación de accesibilidad web se valoran a través de nueve criterios: (1) Facilidad de aprendizaje, (2) Ámbito de aplicación, (3) Evaluación de elementos de visualización, (4) Nivel de accesibilidad, (5) Precisión, (6) Evaluación CSS, (7) Informes, (8) Intuitividad y, (9) Salida estandarizada. Para la consideración de un formato de salida estandar, se tienen cuenta tres finalidades:

- 1) Obtener de manera automática el nivel de accesibilidad web (A, AA, AAA) del LMS en un campo de texto.
- 2) Enlistar los criterios que faltan para lograr con satisfacción el nivel superior consecutivo de accesibilidad
- 3) Calcular el promedio entre 0 y 100 del nivel de accesibilidad web del LMS.

- **Fase Idear:** En esta fase se realiza el análisis de lo que se observó en el Focus Group. Se cuenta con información de diferente índole. Para concretizar las ideas obtenidas se usa una herramienta llamada *Point of View* la cual sintetiza en una frase lo que realmente necesita el usuario y porque lo necesita. Posteriormente con la información

<sup>1</sup>www.moodle.cunorte.udg.mx



se define el MEMCLDM problem y se selecciona las métricas que serán utilizadas para su solución.

El uso de técnicas tales como *Test usabilidad*, cuestionarios (SUS, NPS, Instrumento 1) y un *Checklist* resultante de la observación del *Focus Group*. Al finalizar se procede al diseño del modelo lingüístico. La finalidad es resolver un problema MEMCLDM el cual recibe como entradas las valoraciones de los criterios definidos en la etapa anterior.

- **Fase Prototipar:** En esta fase ya se encuentra definido el modelo lingüístico y se desarrolla un prototipo para la evaluación de la usabilidad y accesibilidad web. Este prototipo es un sistema web que debe ser usable y accesible en sí mismo.
- **Fase Testear:** En esta fase se realiza la evaluación de la usabilidad y accesibilidad mediante el sistema desarrollado. El Checklist se diseñó con los resultados de la aplicación en el primer Focus Group. En esta etapa se utilizan dos Focus Groups, el primero en el Centro Universitario del Norte de la UdG (México) y el segundo en usuarios de la Universidad de Granada (UGR, España) mediante la plataforma LMS Prado. La evaluación de las opiniones emitidas por los expertos en usabilidad se hace a través de la representación lingüística de 2-tuplas introducida por Herrera [19]. La utilización de *A/B testing* en esta fase se considera importante. La evaluación de los usuarios en la interfaz gráfica mediante esta herramienta da como resultado que el sistema sea de un nivel adecuado. La aplicación de la encuesta SUS, NPS e II en esta etapa describe la satisfacción de los usuarios en el sistema de evaluación. En caso de que los resultados no sean favorables, se realiza un proceso iterativo en esta fase hasta lograr un resultado positivo.
- **Fase Implementación:** En esta fase el sistema de evaluación tiene resultados positivos y es usable y accesible en sí mismo. Se implementa en plataformas LMS de Moodle versión 2.x y 3.x siguiendo los lineamientos que Moodle.org detalla para el desarrollo de módulos.

## V. RELEVANCIA

Los puntos a destacar del presente trabajo de investigación son los siguientes:

- 1) Permitirá mejorar la evaluación de la usabilidad de los sistemas informáticos mediante la incorporación de Modelos Lingüísticos para la gestión eficaz de la información cualitativa. Los Modelos Lingüísticos utilizan un lenguaje aproximado al razonamiento de las personas para ayudar en la toma de decisiones del evaluador, debido a que es posible que el evaluador no esté seguro de su valoración, o es difícil hacer valoraciones precisas o cualitativas.
- 2) Este proyecto de investigación basado en DT pone al usuario en el centro del diseño, lo que permite captar en mayor medida las necesidades de todo usuario del LMS.
- 3) Se contemplan las diferentes emociones que tienen los usuarios para identificar puntualmente las actividades que

desatan emociones negativas. Debido a este tipo de emociones, se evalúa negativamente la usabilidad de los sistemas informáticos.

- 4) Se desarrollará un complemento (*plugin*) con licencia libre para el LMS Moodle. Este complemento incorporará: valoración de usabilidad y un método automático para evaluación de la accesibilidad web con la finalidad de validar el acceso a la información a personas con diferentes discapacidades.
- 5) Por último, no es necesario un experto en usabilidad. El LSM es evaluado por el grupo de personas que utilizan los sistemas, por lo tanto se promueve una reducción significativa de costes.

## REFERENCES

- [1] W. Albert and T. Tullis, *Measuring the User Experience: Collecting, Analyzing, and Presenting Usability Metrics*, ser. Interactive Technologies. Elsevier Science, 2013.
- [2] J. Nielsen, "Usability metrics: Tracking interface improvements," *IEEE Softw.*, vol. 13, no. 6, pp. 12–13, Nov. 1996.
- [3] D. V. A. . N. K. L. Chin, J. P., *Development of an instrument measuring user satisfaction of the human-computer interface*. New York: Association for Computing Machinery, 1988.
- [4] K. Jurek and C. Mary, "Sumi: the software usability measurement inventory," *British Journal of Educational Technology*, vol. 24, no. 3, pp. 210–212, 1993.
- [5] J. Kirakowski and B. Cierlik, "Measuring the usability of web sites," *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 42, no. 4, pp. 424–428, 1998.
- [6] P. Jordan, B. Thomas, I. McClelland, and B. Weerdmeester, *Usability Evaluation In Industry*. Taylor & Francis, 1996.
- [7] R. Owen and L. Brooks, *Answering the Ultimate Question: How Net Promoter Can Transform Your Business*. Wiley, 2008.
- [8] J. M. Pearson and A. M. Pearson, "An exploratory study into determining the relative importance of key criteria in web usability: A multi-criteria approach," *Journal of Computer Information Systems*, vol. 48, no. 4, pp. 115–127, 2008.
- [9] M. M. Althobaiti and P. Mayhew, "Assessing the usability of learning management system: User experience study," in *E-Learning, E-Education, and Online Training*, G. Vincenti, A. Bucciero, and C. Vaz de Carvalho, Eds. Cham: Springer International Publishing, 2016, pp. 9–18.
- [10] J. M. Mendel, L. A. Zadeh, E. Trillas, R. Yager, J. Lawry, H. Hagsras, and S. Guadarrama, "What computing with words means to me [discussion forum]," *IEEE Computational Intelligence Magazine*, vol. 5, no. 1, pp. 20–26, 2010.
- [11] S. H. Rubin, "Computing with words," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 29, no. 4, pp. 518–524, 1999.
- [12] L. A. Zadeh, "Fuzzy logic= computing with words," *IEEE Transactions on Fuzzy Systems*, vol. 4, no. 2, pp. 103–111, 1996.
- [13] —, "The concept of a linguistic variable and its application to approximate reasoning—i," *Information sciences*, vol. 8, no. 3, pp. 199–249, 1975.
- [14] R. Montes, A. Sánchez, P. Villar, and F. Herrera, "A web tool to support decision making in the housing market using hesitant fuzzy linguistic term sets," *Applied Soft Computing*, vol. 35, pp. 949 – 957, 2015.
- [15] R. Montes, A. M. Sanchez, P. Villar, and F. Herrera, "Teranga go!: Carpooling collaborative consumption community with multi-criteria hesitant fuzzy linguistic term set opinions to build confidence and trust," *Applied Soft Computing*, vol. 67, pp. 941 – 952, 2018.
- [16] J. Morente-Molinera, G. Kou, I. Pérez, K. Samuylov, A. Selamat, and E. Herrera-Viedma, "A group decision making support system for the web: How to work in environments with a high number of participants and alternatives," *Applied Soft Computing*, vol. 68, pp. 191 – 201, 2018.
- [17] L. A. Zadeh, *Computing with words: Principal concepts and ideas*. Springer, 2012, vol. 277.
- [18] K. T. Atanassov, "Intuitionistic fuzzy sets," *Fuzzy Sets and Systems*, vol. 20, no. 1, pp. 87 – 96, 1986.



- [19] F. Herrera and L. Martinez, "A 2-tuple fuzzy linguistic representation model for computing with words," *IEEE Transactions on Fuzzy Systems*, vol. 8, no. 6, pp. 746–752, Dec 2000.



# Modelo Lingüístico Difuso de Evaluación de la Calidad de la Formación Superior en Entornos Metodológicos de Flipped Classroom y M-learning

Doctorando: Jeovani M. Morales Nieto, Directores: Francisco Herrera and Rosana Montes

*Andalusian Research Institute on Data Science and Computational Intelligence, DaSCI.*

*Universidad de Granada*

Granada, España

Email: jeovani@correo.ugr.es, herrera@decsai.ugr.es, rosana@ugr.es

**Abstract**—En la educación actual la colaboración e interacción para el desarrollo de actividades mediante el uso de la tecnología y dispositivos móviles, así como la *satisfacción del estudiante* y la *comunicación virtual* estudiante-estudiante y estudiante-profesor que se genera al utilizar los dispositivos móviles como herramientas para la educación, son criterios que surgen al integrar metodologías educativas como *Flipped Classroom* (FC) y *M-learning* (ML). Estos criterios suelen utilizar métricas que por su naturaleza se representan mejor como información lingüística, por lo que este trabajo propone realizar un modelo lingüístico difuso para la toma de decisiones que permita evaluar la calidad de la formación superior en un entorno con metodologías combinadas, es decir un entorno FC-ML. Integra los criterios de interacción, colaboración, comunicación virtual y satisfacción del estudiante, denominados criterios FC-ML, a un Sistema de Garantía de Calidad Educativa (SGCE), desarrollado desde la perspectiva de un problema de toma de decisiones lingüísticas multi-experto multi-criterio con un enfoque en computación con palabras. Por otro lado, se propone el desarrollo de un chatbot de Telegram, denominado EDUtrack, que se conectará a un Sistema de Gestión del Aprendizaje (LMS, por sus siglas en inglés) y servirá como medio de comunicación simple bidireccional para la recogida de datos y como apoyo a la evaluación de la calidad educativa.

**Index Terms**—Modelo Lingüístico Difuso, Grantía de Calidad Educativa, Flipped Classroom, M-Learning, Computing with Words, Evaluación de la Calidad educativa

## I. ANTECEDENTES

El concepto de calidad educativa no es fácil de definir, pero en general es el resultado de la interacción entre docentes, estudiantes y los soportes institucionales<sup>1</sup>. El objetivo de implementar un Sistema de Garantía de la Calidad Educativa (SGCE) es responder a los cambios educativos para mantener el aseguramiento de la calidad, al mismo tiempo que garantice las cualificaciones de los estudiantes y su experiencia en la educación haciendo hincapié en la creación de vías de aprendizaje flexible y la contemplación de nuevas modalidades de aprendizaje, tales como *b-learning*.

Así mismo, nuevas metodologías educativas permiten experiencias de aprendizaje, interactivas y colaborativas, entre

ellas: *Flipped Classroom* (FC) y *M-learning* (ML). FC y ML por separado han resuelto diversas necesidades de la educación actual y se han vuelto tendencia en la investigación educativa. Diversos estudios ofrecen evidencias de la efectividad de FC [1], [8] y ML [2], [12] haciendo principalmente una comparativa con el modelo educativo tradicional mediante datos cuantitativos y analizando solo la aceptación de las metodologías sin presentar un marco teórico estable para la evaluación calidad educativa.

Así como FC y ML por separado se han popularizado, la combinación de estas metodologías, es decir un entorno FC-ML, aún no ha sido muy explorado por la comunidad científica, conforme se acota la búsqueda a la combinación de estas metodologías y al aseguramiento de la calidad los resultados disminuyen considerablemente. Por lo tanto, el docente que busca integrar estas metodologías se enfrenta a un nuevo reto y a las carencias en cuanto a la metodología que debe aplicar, por la poca literatura existente hasta el momento.

En la literatura se han encontrado nuevas formas de evaluar la calidad educativa. Por un lado, favoreciendo la colaboración y la interacción entre estudiante-estudiante, estudiante-profesor y estudiante-contenido, conocidas como las interacciones de Moore [11]. Hadjileontiadou et al. [6], señala que algunos de los factores importantes para evaluar la colaboración y la interacción son: *la calidad de la colaboración (QoC)*, *el equilibrio de la actividad colaborativa (BCA)* y *la calidad de las interacciones (QoI)*.

Por otro lado, generando nuevas formas de comunicación virtual en comunidades de aprendizaje. El modelo teórico subyacente a la comunidad de aprendizaje es *Community of Inquiry* (CoI) [5]. Según este modelo, en la comunicación que tiene lugar en una comunidad virtual, siempre hay tres estilos de presencia: *presencia cognitiva*, *presencia social* y *presencia docente*.

Es importante señalar que, en este contexto, diversas métricas para evaluar estos criterios no son numéricas sino de naturaleza cualitativa o lingüística, por lo que tienden a ser vagos o de carácter difuso. *Computing with Words* (CW) es una metodología en la que las palabras se utilizan en lugar de los

<sup>1</sup><http://www.enqa.eu/>

números para la computación y el razonamiento [13]. Se ha utilizado como base computacional para resolver problemas de toma de decisión lingüística (LDM, por sus siglas en inglés) [10], este caso en particular se puede abordar como un problema MEMCLDM (*Multi-Expert Multi-Criteria Lingüistic Decision Making*). Multi-experto, donde cada estudiante es un experto, y multi-criterio, donde los criterios FC-ML, se evaluarán mediante la opinión o percepción de los estudiantes.

## II. HIPÓTESIS DE PARTIDA

La tecnología por sí sola no genera ni provoca creación de conocimientos significativos, es la interacción que tienen los docentes y los estudiantes con la tecnología, así como las metodologías utilizadas para llevar a cabo las actividades correspondientes a los criterios FC-ML. En la literatura se puede encontrar investigaciones que consideran estos criterios como elementos importantes de la educación:

- Jackson [7] analiza diversas muestras de la presencia cognitiva, social y docente en una comunidad mediante diversas herramientas de comunicación.
- Ebrahimpour et al. [4] analiza las percepciones de los estudiantes para la implementación de redes sociales en los programas educativos, con resultados favorables, en particular con la herramienta Telegram.
- Hadjileontiadou et al. [6] describen algunos estudios donde señalan la importancia de la implementación de las tecnologías de la información y comunicación (TIC) y la evaluación de la interacción y la colaboración mediante el uso de LMS en un entorno *b-learning* con implicaciones de lógica difusa.
- Cudney y Ezzell [3] resaltan las ventajas que aportan FC, ML, redes sociales, aprendizajes colaborativos y el aprendizaje autodirigido a la evaluación de la educación.

Sin embargo, cada uno de estos estudios abordan los criterios por separado, y en su mayoría con una perspectiva no lingüística. La pregunta que se pretende resolver con esta investigación y con que se definen los objetivos a desarrollar es:

**¿Se puede usar un modelo lingüístico difuso para evaluar una experiencia educativa cuando se está aplicando un entorno FC-ML?**

## III. OBJETIVOS

El objetivo general de esta investigación es desarrollar un modelo lingüístico difuso de evaluación de la calidad educativa en un entorno FC-ML que integre los criterios FC-ML en un modelo SGCE para una mejor experiencia educativa. De este objetivo se desprenden 4 objetivos específicos:

- 1) Adaptar o Extender un modelo SGCE para incorporar nuevas métricas, (véase Fig. 1).
- 2) Definir la evaluación de la calidad superior como un problema MEMCLDM.
- 3) Desarrollar una herramienta denominada EDUtrack, que facilite la implementación del modelo, automatizando la extracción de datos de las fuentes del modelo lingüístico.

- 4) Dotar a EDUtrack de un sistema de detección de estudiantes de fracaso escolar como método de prevención temprana.

MÉTRICAS DE ENTRADA PARA EL MODELO LINGÜÍSTICO			
Entrada	Métrica	Abreviación	Naturaleza
QoI	Núm. de interacciones Estudiante-Estudiante.	(Chat-Est-Est)	Numérica
	Calidad de la interacción Estudiante-Estudiante.	(Cld-Est-Est)	Lingüística
	Núm. de interacciones Estudiante-Profesor.	(Chat-Est-Prof)	Numérica
	Calidad de la interacción Estudiante-Profesor.	(Cld-Est-Prof)	Lingüística
	Núm. de interacciones Estudiante-Contenido.	(Int-Moodle)	Numérica
	Calidad de la interacción Estudiante-Contenido.	(Cld-Est-Cont)	Lingüística
CoI	Cuestionario para comunicación virtual.	(Q-CV)	Lingüística
	Cuestionario para satisfacción del estudiante.	(Q-SE)	Lingüística
QoC	Autopercepción de la evaluación	(Auto-Eva)	Lingüística
	Evaluación de pares por capsula.	(Eva-Par)	Lingüística
BCA	Media colaborativa de cada planeta en cada métrica de QoC.	(BCA-Planeta)	Lingüística
SRF	Inverso de Calificaciones	(Inv-Cal)	Numérica
	Asistencia de actividades mediante Prado	(Ast-Act-Prado)	Numérica
	Valuación temporal de QoC	(QoC-Tmp)	Lingüística
	Valuación Temporal BCA por planeta.	(BCA-Tmp)	Numérica
	Valuación temporal QoI	(QoI-Tmp)	Lingüística

Fig. 1. Métricas de los criterios FC-ML, para un entorno FC-ML. *QoI*: Calidad de la Interacción, *CoI*: *Community of Inquiry*, *QoC*: Calidad de la Colaboración, *BCA*: Equilibrio de la Actividad colaborativa, *SRF*: *Score Risk Factor*.

## IV. METODOLOGÍA

La propuesta se desarrolla en un entorno FC-ML, el cuál combina las características de las metodologías *Flipped Classroom* y *M-Learning*. FC proporciona las bases para que los estudiantes puedan conceptualizar el conocimiento previo a la clase, entregando contenidos y recursos educativos a los estudiantes mediante el uso de las TIC, permitiendo la interacción estudiante-contenido y mejorando así el aprovechamiento del tiempo en el aula. Por su parte ML, aprovecha las bondades de los dispositivos móviles y sus aplicaciones, como Telegram, que es una aplicación de mensajería instantánea, permitiendo tener un mayor acercamiento a los estudiantes gracias a la interacción, colaboración y comunicación virtual que genera entre estudiante-estudiante, y estudiante-profesor. Combinadas permiten del desarrollo de actividades tanto síncronas como



asíncronas junto con el docente, tanto dentro como fuera del aula, véase Fig. 3.

Se abordará como un problema MEMCLDM (varios expertos, estudiantes y varios criterios, los criterios FC-ML), el cuál puede ser explorado mediante CW, asistido por el modelo Personalized Individual Semantics (PIS) [9] y con una representación lingüística 2-tuplas permitiendo resolver problemas LDM de la misma manera que lo hacen los humanos, tratando con información imprecisa, como mediciones inexactas o conocimiento experto disponible en forma de descripciones verbales. Se desarrolla en 5 fases de las cuales las dos primeras ya se realizaron y actualmente se está iniciando la fase 3:

- 1) **Análisis teórico–metodológico:** Se realizó una revisión de la literatura sobre los modelos y metodologías planteadas, usando bases de datos relevantes (*Scopus* y *Web of Science*). Los resultados indican que tanto FC como ML por separado son una tendencia en la investigación educativa, pero combinadas, disminuyen drásticamente los resultados, véase Fig. 2, detectando así una necesidad de investigación en esta área.

CRITERIOS DE BÚSQUEDA	2012	2014	2016	2018	Total
	2013	2015	2017		
<i>Flipped Classroom &amp; Education</i>	87	700	1273	103	2,163
<i>M-Learning &amp; Education</i>	1122	1606	1595	119	4,442
<i>Flipped Classroom &amp; Education &amp; Evaluation</i>	9	101	156	18	284
<i>M-Learning &amp; Education &amp; Evaluation</i>	124	203	179	15	521
<i>Flipped Classroom &amp; Education &amp; Quality Assurance</i>	0	2	2	2	6
<i>M-Learning &amp; Education &amp; Quality Assurance</i>	8	9	6	1	24
<i>Flipped Classroom &amp; M-Learning &amp; Education</i>	0	9	19	1	29
<i>Flipped Classroom &amp; M-Learning &amp; Education &amp; Evaluation</i>	0	3	0	0	3
<i>(B-learning OR Flipped Classroom OR M-Learning) AND Quality Assurance</i>	3	4	2	0	9
<i>Computing with Words AND (Flipped Classroom OR M-Learning)</i>	5	1	1	0	7
<i>Flipped Classroom &amp; M-Learning &amp; Education &amp; Quality Assurance</i>	0	0	0	0	0

Fig. 2. Revisión de la literatura actual para *Flipped Classroom*, *m-learning* y garantía de la calidad.

- 2) **Evaluación preliminar:** Se realizó un primer caso de estudio sin el modelo lingüístico para recogida de datos, en la asignatura de Fundamentos del Software (FS1718) de 1er semestre de Ingeniería en la Universidad de Granada (UGR) en un entorno FC-ML asistido mediante las TIC a través de Prado2<sup>2</sup>. Se dividió la asignatura en pequeños grupos denominados planetas de no más de

<sup>2</sup>Plataforma LMS de la UGR basada en Moodle: <https://prado.ugr.es/moodle/>

10 integrantes y se trabaja con diversas actividades y recursos, véase Fig. 4:

- **Cápsulas:** Consisten en una serie de videos, recursos y una o varias actividades relacionadas a la temática.
- **Meetings:** Reuniones de 30 min aproximadamente en tiempo real con el profesor a través de Telegram.
- **Chats Colaborativos:** Fuera de los meetings el chat será libre para la colaboración entre los estudiantes y la resolución de dudas entre compañeros.
- **Clases magistrales:** Clases presenciales en donde se profundizarán las temáticas con actividades interactivas y colaborativas.

A la par se realizó la validación por juicio de expertos bajo consenso del instrumento de evaluación de comunicación virtual y satisfacción del estudiante en base al modelo *CoI* mediante números difusos.

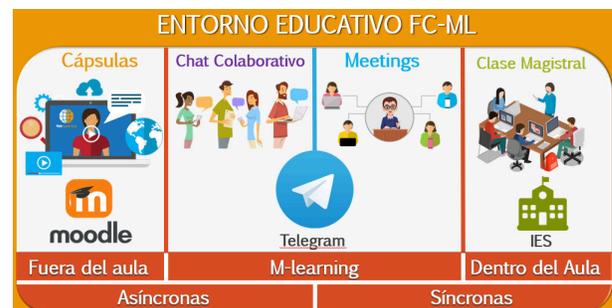


Fig. 3. Un entorno FC-ML permite el desarrollo de actividades síncronas como asíncronas tanto dentro como fuera del aula.

- 3) **Adaptación del modelo lingüístico:** Se adecua un modelo SGCE, con la finalidad de integrar las métricas de los criterios FC-ML, a la evaluación de la calidad de una experiencia educativa FC-ML en un contexto de Educación Superior. Estas métricas por su naturaleza en su mayoría son lingüísticas por lo que se procesaran mediante CW utilizando un modelo de representación lingüística de 2-tuplas y el modelo de Semántica Individual Personalizada (PIS, por su siglas en inglés).
- 4) **Diseño del modelo y de EDUtrack:** Se procede al diseño del modelo lingüístico, véase Fig. 4, implementado mediante EDUtrack para resolver un problema MEMCLDM el cual recibirá como entradas las valoraciones de los criterios FC-ML proporcionadas por Prado2 y Telegram, junto con los resultados del cuestionario de evaluación de comunicación virtual y la satisfacción del estudiante.

*Score-Risk-Factor* (SRF) y *Score-Risk-Students* (SRS), son métricas que se solicitan mediante EDUtrack, la primera es solicitada por cada alumno e informa del riesgo de fracaso académico, mientras que la segunda es solicitada por el docente para conocer a aquellos estudiantes en riesgo dentro del grupo.

Tras el procesamiento se obtendrán 5 valoraciones de salida que permitirán tomar decisiones de forma in-

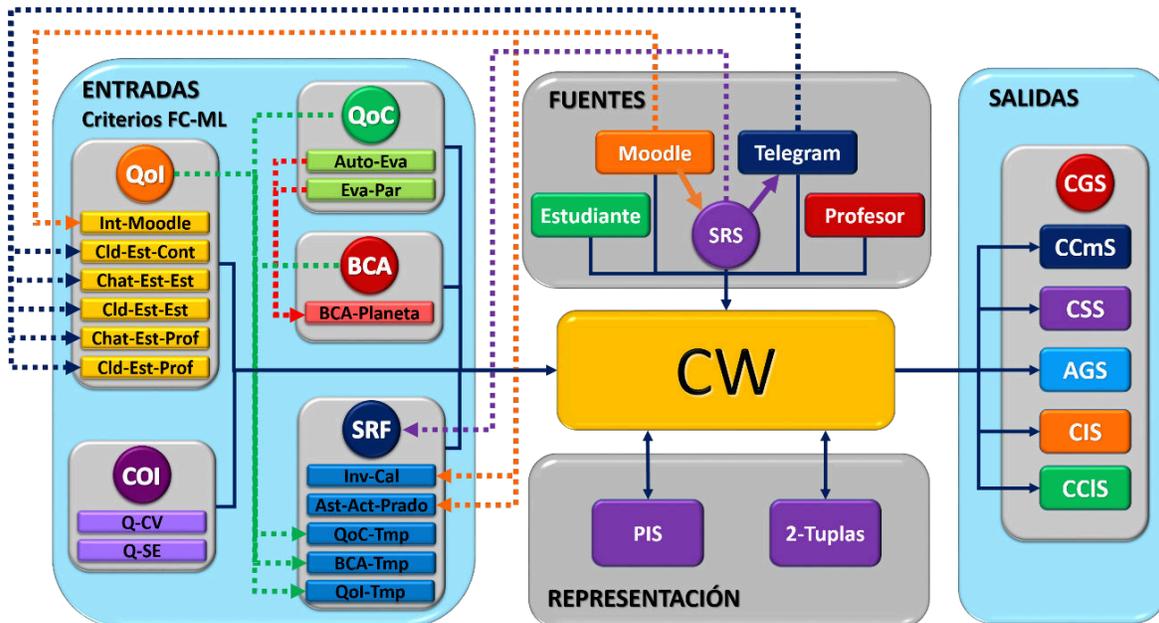


Fig. 4. Modelo Lingüístico para la evaluación de la calidad de la formación superior en un entorno *Flipped Classroom* y *M-learning*.

dependiente para cada criterio: *Average Group Score* (AGS), *Course Interaction Score* (CIS), *Course Satisfaction Score* (CSS), *Course Collaboration Score* (CCIS) y *Course Communication Score* (CCmS). Además, se complementarán para convertirse en el *Course Global Score* (CGS), que indicara el estado general de la experiencia educativa.

- 5) **Implementación y validación:** Se implementa el modelo lingüístico integrando EDUtrack en un segundo caso de estudio para recolección y procesamiento de datos dentro de la misma asignatura, con la misma docente y el mismo entorno FC-ML (FS1819). Como resultado se podrá evaluar los 2 cursos y detectar desviaciones positivas o negativas en el score. Se analizarán los resultados para determinar que recursos y actividades son las que requieren ser modificadas, así como aquellas que suman a la evaluación de la calidad educativa. Con esto se pretende tomar decisiones que ayuden a mejorar la calidad educativa cada ciclo escolar.

## V. RELEVANCIA

Es importante analizar la calidad de la educación no solo desde la perspectiva del desempeño académico, sino que se debe de tomar en cuenta la percepción del estudiante. Por lo tanto, este documento considera al mismo estudiante como experto evaluador para evaluar su propia experiencia de aprendizaje. Además, se propone el desarrollo de un modelo que permita modelar las percepciones de los estudiantes de los criterios FC-ML desde una perspectiva MEMCLDM para integrarlos a un SGCE utilizando un lenguaje natural y comprensible que pueda ser procesado fácilmente mediante la computación con palabras.

Con base en lo anterior, esta investigación aportará a la literatura una base para investigaciones futuras en:

- Evaluación de la calidad educativa en entornos FC-ML.
- Integración de los criterios FC-ML para evaluar la calidad educativa superior.
- El uso de modelos lingüísticos difusos para la evaluación de la calidad de la educación superior, mediante CW, como un problema MEMCLDM.

EDUtrack por su parte, utiliza un modelo de comunicación simple pero muy potente, que gracias al uso cotidiano de aplicaciones móviles como Telegram por parte de los estudiantes, se puede implementar de una forma fácil y cómoda.

Cabe destacar que esta propuesta no solo se adecua exclusivamente a entornos FC-ML, puesto que al ser modulares los elementos de entrada se puede evaluar únicamente aquellos que sean útiles en la modalidad y metodología requerida.

## REFERENCES

- [1] Bishop, J.L., Verleger, M.A., et al.: The flipped classroom: A survey of the research. In: ASEE national conference proceedings, Atlanta, GA. vol. 30-9, pp. 1–18 (2013)
- [2] Crompton, H., Burke, D.: The use of mobile learning in higher education: A systematic review. *Computers & Education* **123**, 53–64 (2018)
- [3] Cudney, E., Ezzell, J.: A systematic review of technological advancements to enhance learning. In: ASEE Annual Conference and Exposition, Conference Proceedings. vol. 122 (2015)
- [4] Ebrahimipour, A., Rajabali, F., Yazdanfar, F., Azarbad, R., Nodeh, M.R., Siamian, H., Vahedi, M.: Social network sites as educational factors. *Acta Informatica Medica* **24**(2), 134 (2016)
- [5] Garrison, D.R., Anderson, T., Archer, W.: Critical inquiry in a text-based environment: Computer conferencing in higher education. *The internet and higher education* **2**(2-3), 87–105 (1999)
- [6] Hadjileontiadiou, S.J., Dias, S.B., Diniz, J.A., Hadjileontiadis, L.J.: Fuzzy logic-based modeling in collaborative and blended learning. *Information Science Reference* (2015)



- 
- [7] Jackson, T.L.: The relationship between student perceptions of satisfaction of social, teaching, and cognitive presence with asynchronous communication tools for online learning in a region v community college. West Virginia University (2015)
  - [8] Karabulut-Ilgu, A., Jaramillo Cherez, N., Jahren, C.T.: A systematic review of research on the flipped learning method in engineering education. *British Journal of Educational Technology* **49**(3), 398–411 (2018)
  - [9] Li, C.C., Dong, Y., Herrera, F., Herrera-Viedma, E., Martínez, L.: Personalized individual semantics in computing with words for supporting linguistic group decision making. *Information Fusion* **33**, 29–40 (2017)
  - [10] Martínez, L., Rodríguez, R., Herrera, F.: *The 2-tuple Linguistic Model: Computing with Words in Decision Making*. Springer International Publishing (2015)
  - [11] Moore, M.G.: Editorial: Three types of interaction. *American Journal of Distance Education* **3**(2), 1–7 (1989)
  - [12] Wei, Y., So, H.J.: A three-level evaluation framework for a systematic review of contextual mobile learning. In: *mLearn*. pp. 164–171 (2012)
  - [13] Zadeh, L.A.: Fuzzy logic= computing with words. *IEEE transactions on fuzzy systems* **4**(2), 103–111 (1996)

# Modelo de toma de decisiones lingüística a gran escala aplicado a la evaluación de proyectos de ciencia ciudadana

Jeronimo Duran\*<sup>†</sup>,

Directores: Francisco Herrera\*<sup>†</sup>, Rosana Montes\*<sup>†</sup>

\*Universidad de Granada, España.

<sup>†</sup> Andalusian Research Institute on Data Science and Computational Intelligence, DaSCI

jeronimoduran@correo.ugr.es

herrera@decsai.ugr.es rosana@ugr.es

Fecha de inicio: Febrero 2018

**Abstract**—La Ciencia Ciudadana incluye la participación de la ciudadanía en los procesos de un proyecto de investigación. Ésta nueva forma de hacer ciencia no puede evaluarse de la forma tradicional, ya que cuenta con diferentes aspectos que no son considerados en los modelos de evaluación tradicionales. Para poder evaluar proyectos de ciencia ciudadana se propone diseñar un modelo basado en la toma de decisiones lingüísticas a gran escala, por lo que se utilizarán expresiones lingüísticas y se incorporará el modelo de representación 2-tuplas para minimizar la pérdida de información en el proceso de toma de decisión, al contemplar a la ciudadanía se considera un gran número de participantes, siendo éste un problema que se puede resolver como Large Scale Group Decision Making.

## I. INTRODUCCIÓN

La ciencia cívica [1] fue el primer concepto que incluía a ciudadanos, quienes de forma independiente o con ayuda de científicos diseñaban o implementaban proyectos científicos. La **Ciencia Ciudadana** (*Citizen Science - CS*)<sup>1</sup> es definida como toda aquella actividad de investigación científica en la que los ciudadanos participan de forma activa, contribuyendo con recursos propios y conocimiento en diversas etapas del proceso de investigación científica.

Es de gran importancia que un proyecto sea evaluado para medir su desempeño, cuantificar el alcance que ha tenido o identificar si ha cumplido o no con los objetivos propuestos. Al ser la ciudadanía un actor importante en la CS, debe estar involucrado en el proceso de evaluación. Se tiene documentación<sup>2</sup> con propuestas de planes de evaluación<sup>3</sup> en donde se mencionan aquellos criterios, métricas e instrumentos de evaluación que se sugieren deben tomarse en cuenta al diseñar un plan de evaluación de un proyecto de CS.

La evaluación del un proyecto de CS puede ser abordado como un proceso de toma de decisiones, en donde un grupo de expertos junto con la ciudadanía, elegirán en que medida

un proyecto cumple con los indicadores de ciencia ciudadana. Existe una gran variedad de modelos para resolver problemas de toma de decisión [2] en donde su aplicación dependerá de la complejidad del problema, el número de individuos involucrados, los recursos que se tengan disponibles y el resultado que se espera. Al tener en cuenta a la ciudadanía, el número de involucrados en la evaluación es elevado, por lo que el modelo lingüístico de evaluación debe ser resuelto como un **Large Scale Group Decision Making (LSGDM)**.

En la actualidad, las redes sociales son los medios de comunicación más utilizados, por lo cual debe de aprovecharse su alcance como medio de difusión a gran escala [3]. Las redes sociales permiten recolección de datos [4] que después pueden ser analizados y representados mediante varios modelos, dichos modelos cuentan con formatos de salida que pueden ser incorporados al estudio o proceso de investigación.

## II. HIPÓTESIS

La hipótesis que planteamos es comprobar que un modelo de evaluación basado en tomas de decisión lingüística a gran escala, centrado en la opinión de los ciudadanos y que incorpore datos de las redes sociales, permitirá determinar de una manera más óptima y desde el punto de vista de los ciudadanos, los objetivos de CS alcanzados.

Basándonos en un conjunto de criterios de evaluación [5], mostrados en la Tabla I, que pueden aplicarse durante la definición inicial del proyecto o en etapas finales, se generarán los indicadores que evaluarán los expertos, que en éste caso serán los ciudadanos; éstos criterios están agrupados en tres dimensiones principales que abarcan aspectos científicos, sociales y de la sociedad<sup>4</sup>.

Las actividades científicas son comúnmente evaluadas en las etapas de resultados y difusión, y dichas valoraciones

<sup>1</sup><http://ciencia-ciudadana.es/wp-content/uploads/2017/05/ObservatorioCC2017Webv2.pdf>

<sup>2</sup><https://www.fecyt.es/es/system/files/publications/attachments/2018/01/guia-basica-proyectos-cultura-cientifica-revisada.pdf>

<sup>3</sup>[http://societize.eu/sites/default/files/SOCIETIZE\\_D5.1.pdf](http://societize.eu/sites/default/files/SOCIETIZE_D5.1.pdf)

<sup>4</sup>FUENTE: The Challenge of Evaluation: An Open Framework for Evaluating Citizen Science Activities. DOI 10.17605/OSF.IO/ENZC9 con licencia abierta CC-BY Attribution 4.0 International. De Barbara Kieslinger, Teresa Schäfer, Florian Heigl, Daniel Dörler, Anett Richter y Aletta Bonn, 2017. Link: <https://osf.io/preprints/socarxiv/encz9>. Traducción y adaptación realizada por Ibercivis



DIMENSIONES	PROCESO Y VIABILIDAD	RESULTADOS E IMPACTOS
CIENTÍFICA	Objetivos científicos Datos y Sistemas Evaluación y adaptación Cooperación y sinergias	Publicaciones y conocimiento científico Nuevos campos y estructuras de investigación Nuevas fuentes de conocimiento
PUNTO DE VISTA DE LOS CIUDADANOS	Adecuación al grupo objetivo Grado de implicación Facilitación y comunicación Colaboración y sinergia	Conocimiento y actitudes Comportamiento y propiedad Motivación y compromiso
SOCIAL-AMBIENTAL-ECONÓMICA	Adecuación al grupo objetivo Implicación activa Colaboración y sinergias	impacto social impacto ambiental Mayor potencial de innovación

TABLE I

CRITERIOS DE EVALUACIÓN DE PROYECTOS DE CIENCIA CIUDADANA.

son realizadas por expertos o por organismos financiadores. En éstos modelos tradicionales no se tiene contemplada la participación ciudadana. La propuesta se centra en la opinión de los ciudadanos, y sus valoraciones serán obtenidas mediante herramientas de evaluación o redes sociales.

Para la recolección de datos, se proponen las siguientes herramientas<sup>5</sup>: Cuestionarios, Entrevistas, Grupos focales y Observaciones. La elección y el uso de dichas herramientas, dependerá del grado de exploración que se necesita sobre el proyecto y/o el conocimiento previo que se tiene del mismo. En nuestro caso nos centraremos en los cuestionarios, ya que será en ese instrumento en donde las respuestas serán representadas como etiquetas lingüísticas.

Los proyectos de CS difieren en algunos aspectos en sus procesos, con respecto a la forma tradicional de hacer ciencia. Al evaluar la ciencia tradicional, solo se toma en cuenta algunas de sus fases, y éstos indicadores suelen ser cuantitativos. En el modelo propuesto, el proceso de evaluación tratará de abarcar todas las fases del proyecto de CS, y los datos de entrada podrán ser cuantitativos, cualitativos o lingüísticos.

La **Computación con palabras (CW)** junto con la *lógica difusa* [6] han demostrado en diversos campos que proporcionan una gran mejora en el proceso de toma de decisiones [7], pues son utilizados para procesar computacionalmente el lenguaje natural. El modelo de evaluación propuesto utilizará las bondades de los modelos lingüísticos para recopilar la opinión de los ciudadanos y poder generar una valoración final expresada en lenguaje natural.

### III. OBJETIVOS

El objetivo general es diseñar un modelo de evaluación, utilizando un esquema teórico de toma de decisiones multicriterio a gran escala, aplicado a proyectos de ciencia ciudadana y asistido por una herramienta que recolecte valoraciones sobre las actividades divulgativas del proyecto.

Los objetivos específicos del proyecto son:

- 1) Definir una herramienta de evaluación que proporcione el estado actual del proyecto de CS en términos de valoraciones lingüísticas en cada una de sus fases, éstas valoraciones pueden ser antes, durante o al finalizar dichas fases.
- 2) Definir una aplicación para dispositivos móviles de la cual se obtengan las valoraciones proporcionadas por los ciudadanos sobre las actividades divulgativas del proyecto de CS.
- 3) Incorporar al modelo de evaluación datos de Twitter como canal de divulgación del proyecto de CS.

### IV. METODOLOGÍA

La propuesta del modelo de evaluación basado en toma de decisiones lingüísticas, contempla su aplicación en un proyecto de ciencia ciudadana denominado **MonuMAI**, el cual consiste en un sistema automático que puede identificar los estilos arquitectónicos de monumentos históricos, apoyada de una aplicación móvil disponible, inicialmente, para los habitantes de la ciudad de Granada. Ésta evaluación incorpora la opinión de los habitantes de Granada como expertos.

El modelo de evaluación lingüístico propuesto consta de tres partes principales, éstas son: recolección de datos, procesamiento de la información y presentación de la información.

Durante el primer año del doctorado se hará un análisis de la bibliografía a utilizar y se diseñará un instrumento de evaluación acorde a las dimensiones y criterios propuestos en la Tabla I, éste instrumento puede ser aplicado en cualquiera de las fases del proyecto, éste proceso formará parte de la recolección de datos .

Una vez elaborado el conjunto de ítems, se diseñarán las escalas basadas en etiquetas lingüísticas, con ellas cada uno de los ítems serán evaluados por parte de los expertos. El instrumento puede ser validado por un conjunto de jueces [8] los cuales someterán a consenso la aceptación instrumento diseñado.

En el segundo y parte del tercer año del doctorado, se diseñará una aplicación (denominada APPlauso), y que pueda

<sup>5</sup><https://www.fecyt.es/es/system/files/publications/attachments/2018/01/guia-basica-proyectos-cultura-cientifica-revisada.pdf>

ser usada por los habitantes de la ciudad de Granada involucrados en el proyecto, para recolectar la valoración que tienen los ciudadanos sobre eventos de divulgación. Para la valoración de los eventos de divulgación en la aplicación, se puede utilizar un modelo basado en evaluación parcial de criterios [9], es decir, que los criterios a evaluar pueden cambiar durante el evento de divulgación, ya que se toma en cuenta la preferencia de los asistentes sobre los criterios.

Se diseñara un modelo para recolección de datos de la red social Twitter, que servirá como canal bidireccional de comunicación entre los ciudadanos y los científicos. Cada una de las dimensiones generara datos cuantitativos y cualitativos, en algunos casos se incorporarán datos que se obtengan de Twitter y de la aplicación que se encargará de recopilar las valoraciones de los eventos de divulgación. La aplicación y el canal de comunicación en Twitter, pueden ser usados en conjunto o de forma separada en cualquiera de las fases del proyecto.

Se tiene un gran número de ciudadanos que emitirán su valoración sobre cada una de los criterios a evaluar, éste panorama sera afrontado como un LSGDM, en donde el proceso de consenso se realiza con grupos formados por un gran número de expertos, se tienen una variedad de modelos, los cuales cada uno tiene ciertas características, que dependiendo del escenario son las ventajas o desventajas que presentan [10], se aplicará un modelo de consenso cuyas característica se acoplen a las circunstancias que se generen con nuestros grupos de expertos, ya que se pueden tomar en cuenta las preocupaciones y satisfacciones de cada experto [11], o se pueden adecuar acorde a las necesidades que se nos vayan presentando como por ejemplo si se nos llegase a presentar una situación con *clusters* o grupos variables [12]

Se utilizarán los **Hesitant Fuzzy Linguistic Term Sets (HFLTS)** [13] para representar información lingüística con incertidumbre, y es compatible con la representación 2-tuplas, que nos ayudará a disminuir la pérdida de información en el proceso de toma de decisión.

Partiendo de la recolección de datos por medio de una herramienta de evaluación previamente definida y validada. Se unificarán para que tengan una representación común y puedan ser computados. Una vez realizado éste proceso se tendrá una base de datos homogénea de expresiones complejas con incertidumbre.

Para resolver el problema lingüístico con las expresiones complejas con incertidumbre surgidas de las evaluaciones de los expertos se realizarán las siguientes fases:

- 1) Fase de Unificación: Las expresiones lingüísticas generadas de la evaluación de los expertos serán expresados en términos de **HFLTS**.
- 2) Fase de Agregación: Se agregan dos operadores de agregación simbólica a las evaluaciones generando un intervalo lingüístico.
- 3) Fase de Explotación: Se crea una relación de preferencia entre las alternativas basado en el intervalo lingüístico del paso anterior. Se aplica un grado de elección para obtener la solución al problema de decisión.

La salida que se obtiene del modelo de representación **HFLTS** serán un conjunto de expresiones lingüísticas sin incertidumbre y con poca pérdida de información gracias a la incorporación de la representación 2-tuplas en el modelo, éste conjunto de expresiones dará lugar a un score lingüístico que formará parte de la valoración de un indicador.

Éstas valoraciones son proporcionadas por cada uno de los ciudadanos involucrados en el proceso de evaluación. Después se realizarán *clusters*, que agrupen a los ciudadanos con valoraciones similares.

Durante tercer año, se diseñará un formato de salida que contenga la evaluación final del proyecto de CS, los datos que se mostrarán incluirán los resultados obtenidos por la herramienta de evaluación validada, el análisis de los datos recopilados del canal de comunicación en la red social Twitter y las valoraciones obtenidas por medio de la aplicación APPlauso de los eventos de divulgación.

El desglose de los datos se podrán realizar por etapas, teniendo una valoración parcial de cada una de ellas, con esto los investigadores sabrán cual fue la evolución de la percepción de los ciudadanos a lo largo del proyecto.

Las valoraciones parciales y finales se expresarán en forma lingüística, para que los ciudadanos al acceder a esa información puedan interpretarla fácilmente.

## V. RELEVANCIA

La ciencia debe estar al alcance de todos y aquellos proyectos que incluyan a la ciudadanía tiene una gran relevancia. las bondades que ofrecen los modelos de representación lingüísticos pueden aplicarse en la evaluación de proyectos de CS, pues permiten que los ciudadanos emitan su percepción expresado en lenguaje natural. El modelo que se propone puede extenderse a otras instancias, mas allá de la evaluación que el equipo de investigadores realiza en los proyectos a su cargo, es decir que instituciones financiadoras y órganos de gobierno puedan utilizar el modelo y adaptarlo a sus necesidades.

## REFERENCES

- [1] F. Clark and D. L. Illman, "Dimensions of civic science: Introductory essay," *Science Communication*, vol. 23, no. 1, pp. 5–27, 2001.
- [2] A. Mardani, A. Jusoh, and E. K. Zavadskas, "Fuzzy multiple criteria decision-making techniques and applications – two decades review from 1994 to 2014," *Expert Systems with Applications*, vol. 42, no. 8, pp. 4126 – 4148, 2015.
- [3] C. Robson, M. Hearst, C. Kau, and J. Pierce, "Comparing the use of social networking and traditional media channels for promoting citizen science," 2013, pp. 1463–1468.
- [4] X. Hu and H. Liu, *Text analytics in social media*, 2012, vol. 9781461432234.
- [5] B. Kieslinger, T. Schäfer, F. Heigl, D. Dörler, A. Richter, and A. Bonn, "The challenge of evaluation: An open framework for evaluating citizen science activities," 2017.
- [6] L. Zadeh, "Fuzzy logic = computing with words," *IEEE Transactions on Fuzzy Systems*, vol. 4, no. 2, pp. 103–111, 1996.
- [7] F. Herrera, S. Alonso, F. Chiclana, and E. Herrera-Viedma, "Computing with words in decision making: Foundations, trends and prospects," *Fuzzy Optimization and Decision Making*, vol. 8, no. 4, pp. 337–364, 2009.



- 
- [8] J. Morales, R. Montes, N. Zermeño, J. Duran, and F. Herrera, “The use of fuzzy linguistic information and fuzzy delphi method to validate by consensus a questionnaire in a blended-learning environment,” *Communications in Computer and Information Science*, vol. 855, pp. 137–149, 2018.
  - [9] I. Pérez, F. Cabrerizo, and E. Herrera-Viedma, “Group decision making problems in a linguistic and dynamic context,” *Expert Systems with Applications*, vol. 38, no. 3, pp. 1675 – 1688, 2011.
  - [10] A. Labella, Y. Liu, R. Rodríguez, and L. Martínez, “Analyzing the performance of classical consensus models in large scale group decision making: A comparative study,” *Applied Soft Computing Journal*, vol. 67, pp. 677–690, 2018.
  - [11] H. Zhang, Y. Dong, and E. Herrera-Viedma, “Consensus building for the heterogeneous large-scale gdm with the individual concerns and satisfactions,” *IEEE Transactions on Fuzzy Systems*, vol. 26, no. 2, pp. 884–898, 2018.
  - [12] Z. Wu and J. Xu, “A consensus model for large-scale group decision making with hesitant fuzzy information and changeable clusters,” *Information Fusion*, vol. 41, pp. 217–231, 2018.
  - [13] R. M. Rodríguez, L. Martínez, and F. Herrera, “Hesitant fuzzy linguistic term sets for decision making,” *IEEE Transactions on Fuzzy Systems*, vol. 20, no. 1, pp. 109–119, 2012.



# Competición de Apps basadas en Inteligencia Artificial

## Presidentes del Comité de Competición:

ALBERTO BUGARÍN

JOSÉ ANTONIO GÁMEZ

## Jurado:

ALBERTO J. BUGARÍN (PRESIDENTE),

BERTHA GUIJARRO, EVA ONAINDIA,

ALICIA TRONCOSO, ÓSCAR LUACES







# Competición CAEPIA-App: MonuMAI, una app para incrementar el valor social del patrimonio-arquitectónico andaluz

Francisco Herrera\*, Álvaro Martínez-Sevilla\*, Siham Tabik\*, Rosana Montes\*, Alberto Castillo\*,  
Teresa Cruz Sánchez† and José Policarpo Cruz‡

\**Instituto Interuniversitario de Investigación en Data Science and Computational Intelligence, DaSCI*  
*Universidad de Granada*

Granada, España

Email: herrera@decsai.ugr.es, asevilla@ugr.es, siham@ugr.es, rosana@ugr.es, albertocl@ugr.es

†*Fundación Descubre*

Granada, España

Email: teresa.cruz@fundaciondescubre.es

‡*Departamento de Historia del Arte*

*Universidad de Granada*

Granada, España

Email: jcruz@ugr.es

**Resumen**—MonuMAI es una aplicación móvil (app) que se desarrolla en el marco de un proyecto de Ciencia Ciudadana del mismo nombre. El objetivo de la app es desarrollar un sistema inteligente para reconocer los diferentes estilos artísticos y aportar información y relaciones sobre las proporciones y otros elementos geométricos en el arte. La app permite usos de divulgación de la ciencia y de fines docentes en áreas como las matemáticas, turismo, arte e historia. En el caso de las matemáticas, ayuda a determinar las relaciones entre las proporciones de los diferentes elementos geométricos en cada estilo artístico. En historia, es una herramienta que puede ayudar a para comprobar las influencias y relaciones entre los estilos de diferentes épocas. En turismo cultural, el turista puede saber el estilo artístico existente en cada parte de un monumento. El canal que conecta al proyecto con la ciudadanía es principalmente la app, pero también se apoya en una web vinculada, que contiene recursos formativos específicos que pretenden generar una experiencia activa que integre monumentos, arte, matemáticas, cultura, ciencia e Inteligencia Artificial. El proyecto está promovido por la Fundación Descubre y la Universidad de Granada.

## I. JUSTIFICACIÓN DE LA INVESTIGACIÓN

La identificación del estilo arquitectónico de un monumento es muy valiosa en muchos campos, en turismo, arquitectura, arte, arqueología y educación. La capacidad de identificar correctamente el estilo de la fachada de un monumento, o del retablo interior ha sido y sigue siendo un privilegio del ojo de un experto. Existen muy pocas publicaciones en esta línea y todas ellas se centran en la clasificación de un elemento concreto de la imagen de la fachada, por ejemplo una torre o ventana, y en un máximo de dos estilos usando métodos clásicos de procesamiento de imágenes [1], [2]. No hay inmediatez ni autonomía por parte del ciudadano ante la simple pregunta que le surge al encontrarse frente a los elementos patrimoniales que fotografía con su móvil.

## II. LA INTELIGENCIA ARTIFICIAL EN MONUMAI

La app MonuMAI, tiene como punto fuerte su componente de Inteligencia Artificial (AI), y es capaz de reconocer de forma autónoma estilos arquitectónicos presentes en las imágenes sincronizadas con el sistema. Las técnicas empleadas (aprendizaje automático o Deep Learning) permiten al sistema ser autónomo en su tarea y mejorar con el uso. Machine Learning (ML) es la rama de la AI que tiene como objetivo desarrollar técnicas que permitan a las computadoras aprender. Las redes neuronales artificiales profundas, comúnmente llamadas Deep Learning (DL), forman un subconjunto de algoritmos de ML capaz de aprender de los datos de forma autónoma sin supervisión humana. Estos modelos son capaces de extraer las características básicas y complejas de los datos de forma automática. En los últimos años, las redes neuronales profundas están mostrando tener un altísimo potencial en el reconocimiento tanto de patrones espaciales como temporales en distintos tipos de datos, como imágenes, vídeos o texto [3], [4]. Hasta la fecha, no existe ninguna herramienta automática basada en el uso de dispositivos *smartphones* para la identificación de los estilos arquitectónicos de los monumentos. Tampoco existe una taxonomía o algún tipo de estructura jerárquica que especifique las relaciones que hay entre los diversos estilos arquitectónicos.

El desarrollo del componente AI de la app se basa en dos pilares, (i) una base de datos amplia de calidad y (ii) un modelo de redes neuronales convolucionales (CNNs). La base de datos ha sido construida usando imágenes de diversos monumentos andaluces seleccionadas de distintos portales de Internet. El modelo de reconocimiento de estilos arquitectónico está basado en el modelo Faster-RCNN, que representa el estado del

arte en detección de objetos en imágenes [5].

### III. TECNOLOGÍAS Y HERRAMIENTAS UTILIZADAS

Para este proyecto se cuenta con un servidor dedicado en exclusiva de reciente adquisición. Para soportar la carga de trabajo que supone el uso de librerías como Tensor Flow se requieren tarjetas gráficas (GPU – *Graphic Process Unit*) de alto rendimiento, y también de un alto grado de especificidad, por ello se utiliza las GF GTX 1080 - 8 GB GDDR5X - PCIe 3.0 x16 - DVI, HDMI, 3 x DisplayPort.

El servidor ejecuta el modelo DL y aloja a su vez la base de datos de fotografías etiquetadas, así como el servidor web del cual la app se nutre de información y actualizaciones (por ejemplo nuevos estilos arquitectónicos o elementos reconocidos dentro de un estilo particular). Gracias al uso de API REST específicas, la app es ligera y de diseño simple. Se ha desarrollado de forma nativa para iOS y Android.

### IV. UTILIDAD DE LA APLICACIÓN

Se desea que los ciudadanos, o los turistas, mientras pasean por las ciudades, adquieran un nuevo concepto del patrimonio inmueble que nos rodea. Que le preste un mayor valor al patrimonio por conocer más de él y hacerlo desde distintos prismas o ciencias que se complementan. Como se muestra en la Figura 1, los usuarios conocen MonuMAI como cuatro elementos que se combinan:

- El arte, por el descubrimiento del estilo artístico subyacente en la fachada del edificio gracias al algoritmo de DL. El usuario una vez descubre el estilo, puede ampliar información desde la app.
- Las matemáticas, a través de la puesta en práctica de ejercicios que permitan descubrir las proporciones empleadas en la construcción de cualquier elemento constitutivo del inmueble.
- La inteligencia artificial, mediante la colaboración activa en la mejora del modelo de reconocimiento y la contribución colectiva al desarrollo de una base de datos estructurada.
- Divulgación de la historia u otra información relevante, que podrá ser compartida y por los usuarios de MonuMAI.
- El uso de la app se convierte en un ejercicio de ciencia ciudadana. El usuario se siente participe con nosotros de estas actividades:
  - Entrenar a nuestro algoritmo, formando parte de un equipo de investigación en Ciencia Ciudadana. Queremos enseñar a nuestro algoritmo a identificar con precisión los diferentes estilos arquitectónicos que aparecen en la fotografía de un monumento.
  - Además, juntos descubriremos si es cierto que hay una tendencia a sentir como más bellas un tipo de proporciones sobre otras; investigaremos juntos sobre el secreto matemático de la belleza de nuestros monumentos.



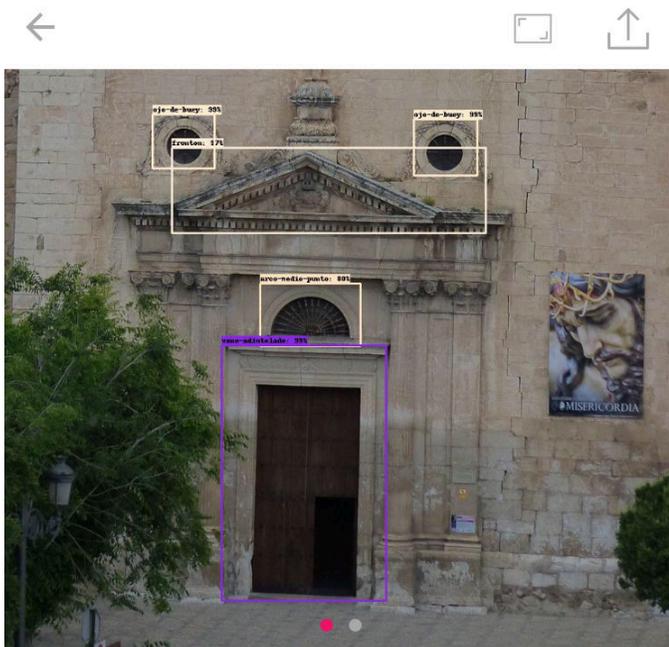
Figura 1. MonuMAI = Monumentos + Matemáticas + IA + Divulgación

### V. CARACTERÍSTICAS DE LA APP MONUMAI

La aplicación nativa para las plataformas iOS <sup>1</sup> y Android <sup>2</sup> permite identificar elementos artísticos en fotografías de monumentos a través de Inteligencia Artificial. Con MonuMAI además se puede acceder a fotografías publicadas por otros usuarios y aprender acerca del arte y las matemáticas presentes en la arquitectura. Se hace a partir del resultado devuelto por el servidor a partir de la imagen enviada por el usuario. Un ejemplo de este resultado se muestra en la Figura 2 que presenta marcos sobre la imagen y un listado de etiquetas-

<sup>1</sup>Apple Store <https://itunes.apple.com/us/app/monumai/id1397249529?i=es&ls=1&mt=8>

<sup>2</sup>Google Play <https://play.google.com/store/apps/details?id=es.everywaretech.monumai>



### Elementos artísticos identificados

- Ojo de Buey (99%) renacentista barroco
- Vano Adintelado (99%) renacentista barroco
- Frontón (97%) renacentista
- Arco Medio Punto (80%) renacentista barroco



Figura 2. Resultado devuelto por el modelo en términos de detección y confiabilidad sobre determinados elementos arquitectónicos

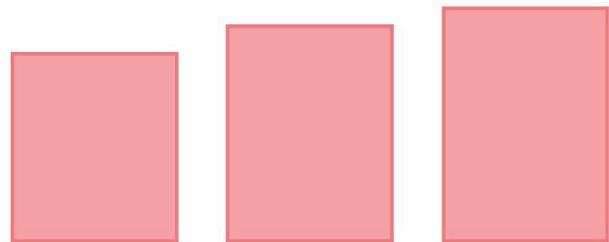
valor devuelto por el algoritmo. La aplicación permite desde ahí obtener un texto de explicación de los elementos arquitectónicos y estilos de arte. En la sección MonuMAI se explica las posibilidades de la Inteligencia Artificial y cómo se aplica en el proyecto.

La aplicación se completa con dos funciones que relacionan las matemáticas y el arte:

- Una encuesta sobre las proporciones en el arte, solicitándole al usuario elegir entre qué proporciones les resultan más atractivas/estéticas. Siguiendo la Figura 3 el usuario selecciona una de entre las proporciones *bajas*, una de entre tres proporciones *medias*, y escoge también de entre tres proporciones *altas*. Finalmente el usuario escoge entre las tres primeras elecciones cuál es la proporción que le parece más bella, sin conocer

Cancelar ¿Cuál es tu proporción favorita?

Escoge, tocando sobre ella, la proporción que te parezca más estética o te guste más de estas 3.



1/4

Siguiente

Figura 3. Una sencilla encuesta nos ayudará a descubrir qué proporciones son más bellas en la actualidad

previamente cuáles son estas.

- La posibilidad de encontrar proporciones matemáticas ( $n^{\circ}$  áureo, raíz de 2, cordobesa, etc.) dentro de la imagen tomada. Para ello se propone al usuario seleccionar un área rectangular en la imagen del monumento (asociada a un arco, portón, ventana, etc.) de forma que la aplicación resuelve a qué proporción se aproxima.

## VI. LA WEB MONUMAI

El portal web <http://monumai.ugr.es>, sirve de difusión para el proyecto y las aplicaciones móviles y permite a cualquiera visualizar la galería de monumentos enviadas por los usuarios de MonuMAI y etiquetadas por el algoritmo de IA. Cabe destacar que el sitio web cuenta con una sección con acceso



identificado para la administración de las imágenes enviadas, permitiendo a los administradores validar su viabilidad para la publicación online y a los investigadores obtener una base de datos de resultados para mejorar el algoritmo de etiquetado. Por otra parte, a nivel de servidor también se ha desarrollado un API REST de servicios para la comunicación con las aplicaciones móviles, permitiendo así la publicación de imágenes y la obtención de resultados.

## VII. CONCLUSIONES

La actual sociedad de la información y del conocimiento, una sociedad en la que la tecnología se integra cada vez más en el día a día, debe y puede destacar el valor cultural, arquitectónico, artístico y matemático que subyace en los cientos de iglesias, catedrales u otros edificios destinados a la administración que pueblan el panorama del patrimonio-inmueble andaluz. MonuMAI consigue ser una herramienta eficiente, basada en IA, que acercar al de forma activa a la ciencia desde distintas perspectivas, al mismo tiempo que de proporciona un rol de divulgador.

## REFERENCIAS

- [1] M. A. W. J. H. S. V. G. L. Mathias, M., "Automatic architectural style recognition," *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3816, pp. 171–176, 2012.
- [2] G. Shalunts, "Architectural style classification of building facade towers," in *Lecture Notes in Computer Science*, B. G. et al. (eds) *Advances in Visual Computing*, Ed. Springer, Cham., 2015, vol. 9474.
- [3] S. I. H. G. Krizhevsky, A., "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, pp. 1097–1105, 2012.
- [4] P. D. H. A. H. F. Tabik, S., "A snapshot of image pre-processing for convolutional neural networks: case study of mnist," *International Journal of Computational Intelligence Systems*, vol. 10, p. 555–568, 2017.
- [5] H. K. G. R. S. J. Ren, S., "Towards real-time object detection with region proposal networks," *Advances in neural information processing systems*, pp. 91–99, 2015.



# Competición CAEPIA-App: Awesome Pic

Fernando Rubio

SIMD Lab, I3A

UCLM

Albacete, España

Email: fernando.rubio@uclm.es

M. Julia Flores

Departamento de Sistemas Informáticos

UCLM

España

Email: julia.flores@uclm.es

Jose M. Puerta

Departamento de Sistemas Informáticos

UCLM

España

Email: jose.puerta@uclm.es

## I. INTRODUCCIÓN

Dentro de la visión artificial existen multitud de problemas relacionados con robótica, salud, seguridad, etc. En los últimos años se ha visto como el paradigma Deep Learning ha revolucionado estos ámbitos, pero de la misma forma otros nuevos problemas más complejos han empezado a surgir a partir de estas soluciones, problemas como el de la evaluación de la calidad estética en fotografía, donde se trata de medir o cuantificar lo atractiva o “bonita” que es una imagen.

### I-A. Evaluación automática de la calidad estética

La evaluación automática de la calidad estética en fotografía es uno de los problemas más desafiantes de la visión artificial dado su carácter altamente subjetivo, ya que dos personas pueden tener opiniones muy distintas sobre la calidad de una imagen e incluso entre expertos puede haber diferencias. Sin embargo, esta dificultad no ha impedido que en los últimos años hayan aparecido gran cantidad de estudios tratando de dar una solución a esta tarea. Este interés se debe principalmente a las posibles aplicaciones, ya que cada día generamos una gran cantidad de imágenes debido, sobre todo, al “boom” de las redes sociales donde una posible ordenación automática de las fotos en base a su calidad es de gran utilidad. Pero también se podría utilizar para hacer recomendaciones de filtros para mejorar el aspecto de nuestras fotografías. Los desarrolladores de teléfonos tratan de ofrecer cada vez mejores cámaras y aplicaciones para sus dispositivos donde estas recomendaciones tienen cabida. Además, existen múltiples opciones en las galerías de las imágenes, desde el agrupamiento de fotografías, hasta la realización automática de videos temáticos a partir de secuencias de fotografías, donde sería muy interesante ordenar por estética las seleccionadas. Otro de los campos de explotación es la publicidad, donde el diseño de imágenes atrayentes para la gente es clave a la hora de hacer anuncios.

Como ya se ha comentado, se trata de un problema con una alta subjetividad, por lo que es difícil medir como de atractiva es una imagen. En la literatura la forma de abordar el problema viene definido en gran parte por las bases de datos disponibles. Generalmente constan de un conjunto de imágenes evaluadas por múltiples personas en base a un determinado ranking. La base de datos más utilizada actualmente es AVA [1] que contiene más de 250.000 imágenes, todas ellas con múltiples votos del 0 al 10 de distintas personas.

### I-B. Problema de clasificación binaria

Gracias a estas bases de datos, es posible convertir la evaluación automática de la calidad estética en un problema de *machine learning*, más concretamente en un problema de aprendizaje supervisado o semi-supervisado, donde tenemos una entrada, que es la imagen, y la salida, que son los votos.

Sin embargo, esta salida es difícil de manejar por muchos algoritmos, además de que esos votos no es la información que espera el usuario final, ya que realmente lo que se busca es saber si una foto es buena o mala en base, quizás a una graduación. Es por ese motivo, que en la mayoría de la literatura las imágenes de las bases de datos son etiquetadas en “snapshots” o “professional shots” en base a estadísticos sobre los votos de las imágenes, como es la media y la moda. Siguiendo con la base de datos AVA, lo más frecuente es que una fotografía se etiquete como “professional shot” cuando la media de sus votos supere el 5, y como “snapshot” en caso contrario.

### I-C. Técnicas de IA utilizadas

En este trabajo hemos seguido el mismo procedimiento, donde a partir de una imagen obtenemos una etiqueta de “snapshot” o “professional shot” y una probabilidad asociada a la clase. En [2] se resume que las técnicas de Transfer Learning sobre redes Deep Learning son las que mejores resultados han obtenido en el problema de evaluación de la calidad estética con el enfoque de clasificación binaria. El Transfer Learning consiste en utilizar una red entrenada para un problema diferente, pero relacionado. Cuando trabajamos con imágenes, el problema por excelencia es ImageNet, donde el objetivo es etiquetar las imágenes con objetos que aparecen en ellas, de entre 1.000 posibles “tags”. De este problema se han obtenido algunas de las arquitecturas de redes neuronales más importantes para el procesamiento de imágenes.

Para este problema, hemos utilizado la arquitectura de AlexNet [3] y los pesos para el problema de ImageNet, donde hemos aplicado *finetuning*, una técnica de Transfer Learning. El proceso consiste en sustituir las últimas capas de la red para ajustarla a nuestro problema, en este caso, hemos sustituido la capa de salida de 1.000 etiquetas de objetos por nuestra salida binaria (“snapshot” o “professional shot”) y por último hemos reentrenado con AVA sólo esta capa final.

Pero en este trabajo no sólo buscamos la mejor solución, si no una que se pueda aplicar a dispositivos móviles y ejecutar



**Figura 1:** Ejemplo de la clasificación *online* donde se puede observar el “emoji” en la esquina superior izquierda para la clase “professional shot”.



**Figura 2:** Ejemplo de la clasificación *offline* donde se puede observar en la parte inferior la puntuación obtenida por nuestra imagen en la red neuronal de nuestro servidor.

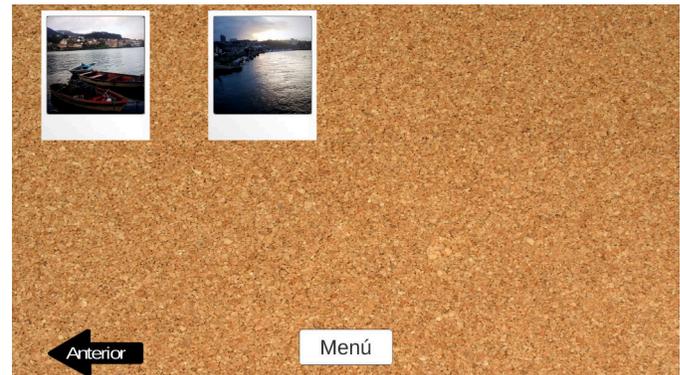
en tiempo real. En [4] se lleva a cabo un estudio del comportamiento de algunas de las técnicas y algoritmos más populares en los problemas de visión artificial aplicados al problema de la calidad estética. En estos casos, la estructura de las propuestas se basa en aplicar un filtro a la imagen para extraer características significativas y reducir la dimensionalidad de la entrada, para después utilizarlo en un clasificador como son algunos modelos probabilísticos, además de otro tipo de modelos.

De entre ellos hay algunas soluciones capaces de ejecutarse con unos requisitos de memoria y tiempo mínimos, como por ejemplo el histograma de grises, una de las técnicas más utilizadas en el procesamiento de imágenes. Mientras que en el lado de los clasificadores nos encontramos con que Naïve Bayes es el que mejores tiempo de respuesta nos ofrece, además de que sus resultados son aceptables dentro del estado del arte. Este enfoque se ha utilizado para esta primera versión de la app, pero una de las líneas de investigación que llevamos a cabo es el mejorar este procesamiento en tiempo real en base a redes Deep Learning mucho más eficientes y menos complejas que aún mantengan unos resultados significativos en sus predicciones.

## II. DESCRIPCIÓN DE LA APP

**Awesome Pic**<sup>1</sup> es una aplicación de fotografía capaz de medir la calidad estética de las imágenes tomadas por la cámara. La app consta de una cámara, una pantalla de previsualización de la fotografía, una galería de imágenes y un menú de configuración. A continuación vamos a describir en más detalle cada una de estas pantallas:

- La cámara es similar a la que viene por defecto en los dispositivos móviles y que permite tomar capturas o imágenes digitales. Dentro de la cámara contamos con las opciones de tomar la imagen, navegar a la galería o salir. En la cámara también aparece información sobre la calidad estética en tiempo real u *online* de lo que se previsualiza y que se obtiene directamente por la app. Esto se puede observar en la Figura 1.



**Figura 3:** Galería de Awesome Pic.

- Una vez la foto es tomada, pasamos a la pantalla de previsualización como en la Figura 2, donde aparece la imagen capturada por la cámara en el momento que se pulsa el botón. En esta pantalla disponemos de opciones para almacenar la imagen en la galería, descartarla o hacer una evaluación más precisa *offline* de la calidad estética mediante un servicio externo.
- En la galería podemos visualizar las imágenes almacenadas, como se muestra en la Figura 3.
- En el menú de configuración podemos cambiar el idioma de la app, el tamaño de la fuente y aplicar un filtro de alto contraste.

### II-A. Evaluación online

En la primera evaluación de la calidad estética, la clasificación se lleva a cabo en tiempo real y en un dispositivo móvil. Esto supone unas restricciones de tiempo y memoria muy altas para realizar el tratamiento de la imagen y su procesamiento por el modelo aprendido.

Como ya hemos comentado en las técnicas utilizadas, hemos seleccionado y aprendido un modelo Naïve Bayes gaussiano con la base de datos AVA convertida a histograma de grises de tamaño 255. El motivo de elegir esta combinación es lo rápido que son ambos procesos y que esto permite ejecutar la evaluación completa en tiempo real y sin consumir grandes recursos del dispositivo móvil.

<sup>1</sup><https://www.youtube.com/watch?v=uanPRdW7iTU>



La salida del modelo es la clasificación que puede ser una “snapshot” o “professional shot” y, dependiendo de esto, mostramos en la esquina superior izquierda un “emoji” como el que se muestra en la Figura 1 que, con el color y la expresión de la cara, nos indica el resultado de la clasificación:

- Rojo, cara de enfado: fotografía de mala calidad o “snapshot”.
- Verde, cara alegre: fotografía de calidad o “professional shot”.

Esta información se actualiza en cada frame mientras observamos con la cámara, por lo que los “emojis” varían hasta que se toma la foto.

### II-B. Evaluación offline

La segunda clasificación se realiza mediante una consulta a un servicio externo implementado por nosotros para la aplicación. Una vez la imagen es capturada es posible enviarla a dicho servicio mediante un botón de lupa que aparece en la esquina superior derecha. En este caso no tenemos las restricciones de tiempo y recursos que en el caso anterior, ya que en el servidor contamos con una tarjeta gráfica dedicada al cómputo y de cierto tiempo para recibir la respuesta. Obviamente no podemos esperar horas a que se obtenga el resultado, pero si unos cuantos segundos.

Este servicio realiza una clasificación binaria con algoritmos más precisos, en este caso, el modelo AlexNet adaptado a la evaluación de la calidad estética con Transfer Learning. De la clasificación se obtiene también una probabilidad o certeza con la que se ha realizado dicha clasificación. Si nos quedamos con la probabilidad de la clase “professional shot” obtendremos un valor donde el 0 representa que se trata de una “snapshot” con un 100 % de certeza y que tiene una calidad pésima, mientras que una puntuación cercana a 100 representa una imagen de gran calidad. En resumen, cuanto más alto sea este valor, más probable será de que se trate de una “professional shot” y de que esa imagen sea atrayente a una mayor cantidad de gente.

Cuando la imagen ha sido procesada por el servidor, este devuelve la probabilidad antes mencionada que es mostrada en un recuadro en la parte inferior como vemos en la Figura 2, indicando así su calidad. Una vez hecho esto podremos elegir entre almacenar la foto en la galería o descartarla.

### II-C. Tecnologías y herramientas

Para el desarrollo de la aplicación móvil se ha utilizado Unity3D [5], uno de los motores de juego más populares y más versátiles. El uso de esta herramienta permite crear apps multiplataforma, lo que incluye Android e iOS, y dota a las apps de un aspecto más atractivo y original. El lenguaje de programación utilizado es C# donde se implementan las funciones de procesamiento de imágenes y algunos de los algoritmos de aprendizaje automático para la evaluación de la calidad estética en tiempo real.

Además de la app se ha creado un servicio en Python para hacer consultas más precisas sobre la calidad y que requieren de un cómputo mucho mayor. Las llamadas a dicho servicio se gestionan a través de Flask [6] y la librería Caffé [7]. Por

último, el servicio se ejecuta a través de un contenedor de Docker [8].

## III. UTILIDAD Y VIABILIDAD DE LA APP

Se trata de una primera versión de la app donde se aprecian dos tipos de recomendaciones sobre la calidad de las imágenes, una en tiempo real que toma dos valores y otra más precisa una vez la imagen ha sido tomada, donde se evalúa del 0 al 100.

Es indudable que cualquier aficionado a la fotografía puede beneficiarse de la aplicación y cualquier persona puede ver mejorada la calidad de sus imágenes, ya sea para subirlas a redes como Instagram o Facebook o para un uso más personal. Además, la puntuación obtenida por el servicio puede utilizarse para la ordenación de fotografías o la comprobación de que filtros benefician o perjudican a una determinada imagen. Se trata de una aplicación única, ya que no hemos sido capaces de encontrar otra que sea capaz de valorar la calidad estética de las imágenes tomadas.

La aplicación se encuentra disponible para todo el mundo de forma gratuita a través de la Play Store de Android<sup>2</sup> y no requiere de paquetes, ni de ningún tipo de aplicación adicional. En este sentido hace que su descarga y manejo sean muy sencillos, además de que dispone de varios idiomas. La mayor limitación viene del lado del servicio, ya que se encuentra desplegado en una máquina que no está preparada para un volumen de peticiones alto o una escalabilidad grande de usuarios.

## IV. CONCLUSIONES

Se trata de la primera versión de la app **Awesome Pic** donde utilizando algoritmos de aprendizaje automático hemos sido capaces de resolver el problema de la evaluación de la calidad estética en fotografía y de plasmar dichos resultados en una cámara capaz de mostrar información sobre la calidad de las imágenes tanto *online* como *offline*.

El objetivo de esta aplicación es plasmar los resultados obtenidos en nuestro trabajo de investigación en este campo de la visión artificial. Nuestra intención es que conforme mejoren dichos algoritmos y técnicas, poder incluirlos en la app y mejorar su comportamiento, así como incluir nuevas funcionalidades, como puede ser la recomendación de filtros o un sistema de puntuación más precisa en tiempo real. Otra de las mejoras consiste en desplegar el servicio en la nube, más concretamente en AWS, mejorando el tiempo de respuesta, la capacidad de recibir más peticiones y de aumentar la escalabilidad o que incluso se pueda utilizar dicho servicio fuera de la aplicación con otros fines.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado con los fondos FEDER y el Gobierno Español (MICINN) a través del proyecto TIN2016-77902-C3-1-P.

<sup>2</sup><https://play.google.com/store/apps/details?id=com.Frubio.AwesomePic>

## REFERENCIAS

- [1] N. Murray, L. Marchesotti, and F. Perronnin, “Ava: A large-scale database for aesthetic visual analysis,” in *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*. IEEE, 2012, pp. 2408–2415.
- [2] Y. Deng, C. C. Loy, and X. Tang, “Image aesthetic assessment: An experimental survey,” *IEEE Signal Processing Magazine*, vol. 34, no. 4, pp. 80–106, 2017.
- [3] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [4] F. Rubio, M. J. Flores, and J. M. Puerta, “Drawing a baseline in aesthetic quality assessment,” in *Tenth International Conference on Machine Vision (ICMV 2017)*, vol. 10696. International Society for Optics and Photonics, 2018, p. 106961M.
- [5] U. G. Engine, “Unity game engine-official site. <http://unity3d.com> [accessed: September 6, 2018.]”
- [6] F. A Python Microframework, “<http://flask.pocoo.org> [accessed: September 6, 2018.]”
- [7] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell, “Caffe: Convolutional architecture for fast feature embedding,” in *Proceedings of the 22nd ACM international conference on Multimedia*. ACM, 2014, pp. 675–678.
- [8] Docker, “Docker-official site. <https://www.docker.com> [accessed: September 6, 2018.]”



# Competición CAEPIA-App: senseUMA

Jamal Toutouh and Enrique Alba

Departamento de Lenguajes y Ciencias de la Computación,  
Universidad de Málaga,  
Málaga, Spain  
Email: {jamal,eat}@lcc.uma.es

**Resumen**—Este documento presenta la aplicación móvil *senseUMA*. Dicha aplicación se ha desarrollado para que los usuarios de la universidad puedan acceder a información en tiempo real sobre diferentes aspectos de la realidad del campus, por ejemplo, el nivel de ruido y la afluencia de gente en diversas zonas del campus. A su vez, se han implementado diferentes métodos de inteligencia artificial para realizar tareas más avanzadas como la predicción y la clasificación de dicha información.

## I. INTRODUCTION

La aplicación de inteligencia artificial (IA) en el diseño de soluciones para Ciudades Inteligentes ha permitido el surgimiento de multitud de servicios avanzados para la ciudadanía [1], [2]. Estas nuevos servicios ofrecen soluciones para mejorar la eficiencia en la movilidad, la recogida de residuos y la gestión de la energía [3], [4], [5], [6], entr otros.

Las universidades pueden ser vistas como pequeñas ciudades, puesto que los campus universitarios cubren grandes áreas y la comunidad universitaria suele incluir miles de personas. Así, las soluciones aplicadas sobre Ciudades Inteligentes para implementar Campus Inteligentes (*Smart Campus*) para mejorar el día a día de los miembros de la comunidad universitaria y de aquellos usuarios que crucen por los campus.

El Campus de Teatinos de la Universidad de Málaga cubre un área considerable dentro de la ciudad de Málaga (aproximadamente 2 kilómetros<sup>2</sup>). Por dicho campus cada día transitan miles de personas pertenecientes a la comunidad universitaria (como alumnos, docentes y personal), además de viandantes que cruzan dicha zona de la ciudad. Estos números nos invitan a entender que este campus, como otros, pueden ser vistos como pequeñas ciudades. Así, aparecen retos a tratar como en dichas ciudades aplicando soluciones similares las empleadas en Ciudades Inteligentes. En este trabajo se presenta una aplicación, *senseUMA* que pretende paliar diferentes problemas relacionados con la movilidad dentro del campus ofreciendo información de utilidad a los usuarios.

La idea fundamental de este proyecto es la de recolectar datos mediante sensores que hemos instalado en diferentes zonas de interés. Estos datos son relativos a la movilidad de peatones y vehículos, así como mediciones del ruido ambiental. El análisis de la información que se genera sirve como base para la detección de los posibles patrones de movilidad y flujos vehiculares que ayudan al entendimiento de la compleja dinámica de estos agentes dentro del campus.

Se ha desarrollado una aplicación móvil cuyas funcionalidades principales son: *i*) mostrar la información actual recogida

por dichos sensores en el campus, *ii*) mostrar datos históricos, *iii*) facilitar la descarga de dicha información al dispositivo móvil y *iv*) ofrecer predicciones precisas sobre lo mismo.

A continuación se describe la funcionalidad principal de *senseUMA*, se introduce cómo se ha implementado (tecnologías y técnicas de IA aplicadas), se discute sobre utilidad y viabilidad de la misma y se tiene el enlace para descargar la misma.

## II. FUNCIONALIDAD PRINCIPAL

El sistema de medición en el que se basa *senseUMA* ha sido implementado e instalado en campus por nuestro grupo [7]. Este sistema recopila datos relativos a la movilidad de los alumnos y el ruido, aunque la modularidad del sistema de medida nos va a permitir extender el sistema con sensores de otro tipo (como por ejemplo, humedad y temperatura). A su vez, se aplican diferentes técnicas de aprendizaje automático (*machine learning*): como la fusión de los datos, la extracción de características o detección de patrones, para la extracción de conocimiento sobre la movilidad y el ruido ambiente.

La aplicación móvil desarrollada, *senseUMA*, ofrece las siguientes funciones principales, que le serán útiles a los usuarios:

- **Mostrar** una gráfica con la evolución durante la última hora del ruido ambiente en los puntos de interés en los que se lleva a cabo la medición (ver Figura 1). Así, también se puede mostrar información histórica durante un día completo o una semana determinada elegida por el usuario (ver Figura 2).
- **Descargar** al dispositivo los datos recogidos por los sensores. Así, el usuario puede tener acceso en forma de archivo CSV a los datos brutos o los mismos tras haber sido procesados.
- **Predecir** el ruido ambiente que se va a dar en un punto de medición en cualquier momento en el futuro elegido por el usuario.
- **Mostrar** en un mapa la ubicación en la que están instalados los sensores y el estado actual de los mismos (conectividad y funcionamiento).

Tal y como se ha modelado y desarrollado la aplicación móvil, esta se puede extender para que se pueda mostrar, descargar y predecir información sobre otros aspectos del campus, como la movilidad de los alumnos, de forma directa y sin esfuerzo.

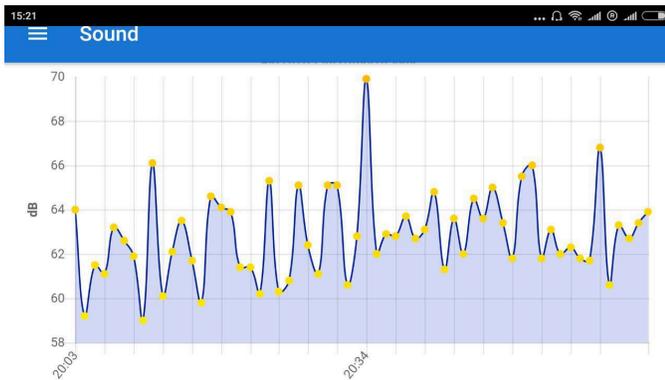


Figura 1: Gráficas de la evolución del ruido: Información en tiempo real (toda la última hora).

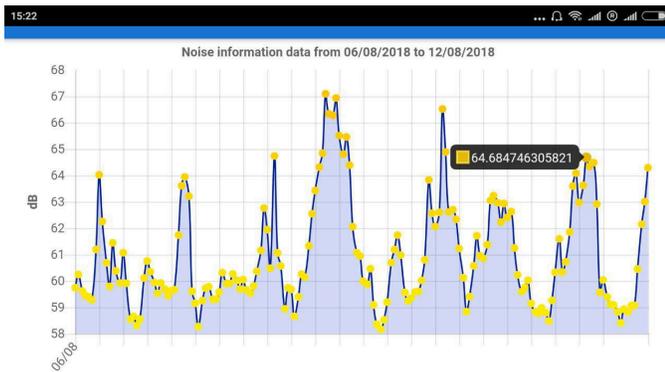


Figura 2: Gráficas de la evolución del ruido: Información histórica de una semana.

### III. IMPLEMENTACIÓN

Para que *senseUMA* pueda ofrecer los servicios presentados en la sección anterior tienen que comunicarse el servidor central con los sensores y con los usuarios (la aplicación móvil), tal y como se muestra en la Figura 3. La comunicación entre el servidor y el sistema de medición (sensores) se realiza para obtener los datos obtenidos por los sensores y para re-configurar los sensores si hiciera falta. La aplicación móvil obtiene del servidor central la información necesaria para generar las gráficas que se muestran al usuario y para poder hacer las predicciones. En esta sección se presentan las tecnologías necesarias para la implementación de *senseUMA* y las técnicas de IA empleadas.

#### III-A. Tecnologías empleadas para el desarrollo

Para el desarrollo tanto del sistema de medición (software de los sensores) como de la aplicación móvil se ha llevado a cabo empleando tecnologías actuales.

Como los sensores están fabricados tomando como base el ordenador de bolsillo *Raspberry PI*, el software de los mismos se ha desarrollado usando *Python*. Así, la comunicación entre los mismos y el servidor central se realiza mediante un esquema cliente-servidor empleando *Python* y *PHP*.

#### SENSORES

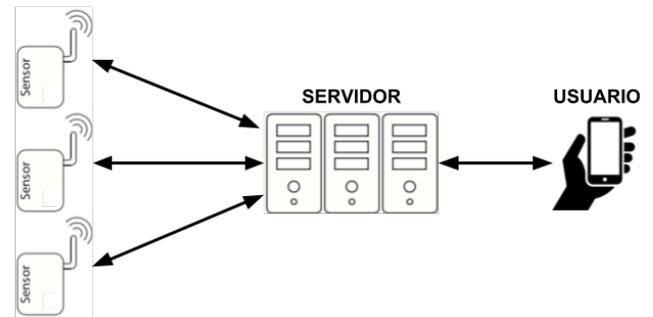


Figura 3: Esquema básico del sistema completo empleado para el funcionamiento *senseUMA*.

En el servidor central los datos se guardan en una base de datos *MySQL*, pero antes se tratan empleando métodos implementados usando *Python* y la biblioteca de análisis de datos y visualización *Pandas*. Así mismo, se han implementado los métodos de aprendizaje automático empleando una biblioteca de *Python* específica para ello, la *scikit-learn*.

La aplicación móvil se ha desarrollado empleando el *Framework Ionic* que permite el desarrollo de aplicaciones móviles multiplataforma empleando lenguajes como *HTML*, *Javascript* y *CSS*. De este modo se facilita el acceso al usuario, puesto que este modo de desarrollo de aplicaciones móviles permite compilar el código para que genere un objeto ejecutable por varios sistemas operativos móviles como *Android* o *iOS*.

#### III-B. Técnicas de IA aplicadas

La aplicación propuesta requiere de la aplicación de varias técnicas de *machine learning* tanto para la extracción del conocimiento como para la predicción. Estos métodos se ejecutan en el servidor y posteriormente se envía a la aplicación móvil la información necesaria para poder dar los servicios presentados.

La evolución temporal del ruido (o de cualquier otro dato) se caracteriza utilizando regresión polinómica. Así mismo, para que el ajuste de la curva sea la más adecuada se ha empleado un método de extracción de características (o *feature selection*) para seleccionar qué franjas horarias ofrecen datos que mejor ajustan a la curva de todo el día. Un algoritmo evolutivo ha seleccionado aquellas franjas horarias que mejor caracterizan y mejor ajustan la curva [8].

Además, se ha utilizado agrupamiento de datos por *K-Means Clustering* para ver si los datos se pueden agrupar por días. Obteniendo que los días se pueden separar en laborables, sábados y domingos o festivos [8].

Este método se va a ejecutar al principio de cada mes, empleando todos los datos capturados que se tienen en la base de datos. La aplicación móvil se descargará la información necesaria para generar el polinomio de regresión que permite predecir el ruido que se va a dar cuando se especifica un día y una hora determinada.



Principalmente, se ha aplicado un algoritmo evolutivo para la extracción de características (o *feature selection*) agrupamiento de datos por *K-Means Clustering* y finalmente predicción mediante regresión polinómica y redes neuronales.

#### IV. UTILIDAD DE *senseUMA*

La principal utilidad que tiene *senseUMA* es que permitirá a los usuarios de la aplicación conocer mejor el estado actual del campus en temas de movilidad y contaminación sonora. Así como predecir esos mismos aspectos. Eso es importante para que los miembros de la comunidad universitaria puedan organizarse mejor para moverse por el campus o para llegar al mismo. Cabe destacar que tanto el sistema de medición, los sensores y la aplicación móvil se han diseñado e implementado para poder ampliar los datos que se miden. Por ejemplo, se ha pensado incluir sensores de temperatura y humedad.

#### V. DESCARGA

La aplicación *senseUMA* se encuentra para su descarga en la siguiente ruta: <http://jamal.es/downloads/senseuma.apk>.

#### ACKNOWLEDGMENT

Este trabajo ha sido parcialmente financiado por el ministerio MINECO y proyectos FEDER TIN2016-81766-REDT (<http://cirti.es>) y TIN2017-88213-R (<http://6city.lcc.uma.es>). Universidad de Málaga. Campus Internaciona de Excelencia Andalucía TECH.

#### REFERENCIAS

- [1] A. Meijer and M. P. R. Bolívar, "Governing the smart city: a review of the literature on smart urban governance," *International Review of Administrative Sciences*, vol. 82, no. 2, pp. 392–408, 2016.
- [2] A. Cocchia, *Smart and Digital City: A Systematic Literature Review*. Cham: Springer International Publishing, 2014, pp. 13–43.
- [3] C. Cintrano, D. H. Stolfi, J. Toutouh, F. Chicano, and E. Alba, "Ctpath: a real world system to enable green transportation by optimizing environmentally friendly routing paths," in *International Conference on Smart Cities*. Springer, 2016, pp. 63–75.
- [4] D. H. Stolfi and E. Alba, "Smart mobility policies with evolutionary algorithms: The adapting info panel case," in *Proceedings of the 2015 Annual Conference on Genetic and Evolutionary Computation*, ser. GECCO '15. New York, NY, USA: ACM, 2015, pp. 1287–1294.
- [5] A. Camero, J. Toutouh, D. H. Stolfi, and E. Alba, "Evolutionary Deep Learning for Car Park Occupancy Prediction in Smart Cities," in *Learning and Intelligent OptimizatiON (LION) 12*. Springer, 2018, pp. 1–15.
- [6] J. Toutouh, D. Rossit, and S. Nesmachnow, "Computational intelligence for locating garbage accumulation points in urban scenarios," in *Learning and Intelligent OptimizatiON (LION) 12*. Springer, 2018, pp. 1–15.
- [7] J. Toutouh, J. Arellano-Verdejo, and E. Alba, "Enabling low cost smart road traffic sensing," in *The 12th edition of the Metaheuristics International Conference (MIC 2017)*, 2017, pp. 13–15.
- [8] J. Luque, J. Toutouh, and E. Alba, "Reduction of the Size of Datasets by using Evolutionary Feature Selection: the Case of Noise in a Modern City," in *18th Conference of the Spanish Association for Artificial Intelligence, CAEPIA 2018*, 2018, pp. 1–10.



# Competición de Vídeos Divulgativos

## **Presidentes del Comité de Competición:**

JOSÉ ANTONIO GÁMEZ

ALBERTO BUGARÍN

## **Jurado:**

SENÉN BARRO AMENEIRO (PRESIDENTE),

JUAN MANUEL CORCHADO, ÓSCAR CORDÓN,

MARÍA JOSÉ DEL JESUS, JOSÉ A. GÁMEZ







# Competición Vídeo: ¿Cómo puedo saber si el resultado de un clustering es lo suficientemente bueno?

José María Luna-Romera and José C. Riquelme Santos  
Departamento de Lenguajes y Sistemas Informáticos  
Universidad de Sevilla  
Sevilla, España

**Abstract**—En este vídeo divulgativo se hace una introducción a una de las técnicas de análisis de datos más usada, el clustering. En él, se explica a través de sencillos ejemplos qué es el clustering y cómo se analizan las distintas soluciones que ofrece a través de diferentes índices de validación.

**Index Terms**—Análisis de clustering, validación de clustering

## I. HERRAMIENTAS Y MATERIALES

Para la elaboración del vídeo se han usado dos herramientas principalmente: Microsoft Power Point, para la elaboración de las diferentes pantallas incluyendo las animaciones de las figuras; Pinnacle Studio [1], que es un programa de edición de vídeo que nos ha permitido añadir las pistas de audio, así como controlar los tiempos de una manera más cómoda a Power Point.

## II. LINK DEL VÍDEO

<https://youtu.be/ERDjUM78H1Q>

## III. JUSTIFICACIÓN

El tema principal del vídeo es la validación de clustering. Se ha escogido esta técnica con el fin de acercar a una audiencia no especializada el clustering, una de las técnicas de análisis de datos más usada y nuclear en el aprendizaje no supervisado. Además, con el objetivo de profundizar en el tema, se da una visión de los índices de validación de clustering para motivar al espectador a plantearse algunas preguntas y cómo llegar a responderlas. A pesar del amplio uso del clustering, sus técnicas de validación son bastante desconocidas, si las comparamos, por ejemplo, a la amplia literatura sobre cómo acreditar la bondad de un clasificador.

La validación del clustering es una de las cuestiones más importantes en el análisis clustering. De hecho, se podría afirmar que medir la calidad de una solución de clustering es tan importante como el método de clustering en sí [2]. Para ello, en la literatura se definen índices de validación de clustering (CVI) que miden la calidad de la solución. Estas medidas podrían clasificarse en CVI internos y externos [3], [4]. Los CVI internos se basan en cómo se distribuyen los objetos en los distintos clusters utilizando sólo la distancia entre los objetos. Por otro lado, los índices externos se apoyan en posibles etiquetas de los objetos que puedan proporcionar

algún tipo de información externa para medir la calidad del clustering [5].

## IV. RECURSOS

En primera instancia se quiso realizar el vídeo usando algún tipo de herramienta que facilitara la elaboración de material didáctico por medio de animaciones. Existen en el mercado servicios online como VideoScribe [6], Doodly [7] o Animaker [8], que a través de una sencilla e intuitiva interfaz permiten realizar vídeos con animaciones, figuras, iconos e incluso personajes. Todos estos servicios disponen de un periodo de prueba en el cual puedes probar la herramienta e incluso algunas de ellas permiten la exportación del vídeo a baja resolución. El inconveniente que encontramos al usar estas herramientas es que al tratarse de versiones de prueba, solo algunas permitían exportar el vídeo y lo hacían dejando una marca de agua.

Como se ha comentado en el apartado anterior, finalmente se ha usado Microsoft Power Point para elaboración de las diferentes pantallas que van apareciendo en el vídeo y Pinnacle Studio para añadir las pistas de audio y realizar el control de tiempos de cada pantalla.

## V. UTILIDAD

Se ha elaborado un vídeo que permite a una audiencia no especializada introducirse en una de las técnicas de aprendizaje no supervisado más usadas de una manera fácil de entender. Además, se ha querido dar un paso más, presentando un nuevo concepto como puede ser la validación del clustering, y qué tipos de técnicas existen. Todo ello se muestra a través de sencillos ejemplos y se ilustra de manera gráfica qué es el clustering y cómo se puede validar la solución.

El vídeo ha sido visualizado por personas con desconocimiento total de la materia, y aunque ha habido diferentes valoraciones, por lo general han sido positivas, destacando la facilidad del lenguaje empleado y el acercamiento de algo complejo a través de ejemplos gráficos.

## VI. CONCLUSIONES

Se ha elaborado un vídeo divulgativo de corta duración para acercar a una audiencia general, una técnica fundamental en el análisis de datos. El vídeo incluye una explicación



general del clustering además de dos tipos de técnicas de validación. A pesar de ser el clustering una técnica muy usada en múltiples ámbitos, no es muy abundante los trabajos divulgativos sobre su validación, a diferencia de las técnicas de aprendizaje supervisado, con mucha mayor presencia en ámbitos científicos.

#### REFERENCES

- [1] P. Studio, “Pinnacle Studio: software de edición de vídeo y grabación de pantalla,” <https://www.pinnaclesys.com/es/products/studio/>, 2018, [Online; accessed september-2018].
- [2] A. K. Jain, “Data clustering: 50 years beyond K-means,” *Pattern Recognition Letters*, vol. 31, no. 8, pp. 651–666, jun 2010. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0167865509002323>
- [3] O. Arbelaitz, I. Gurrutxaga, J. Muguerza, J. M. Pérez, and I. Perona, “An extensive comparative study of cluster validity indices,” *Pattern Recognition*, vol. 46, no. 1, pp. 243 – 256, 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S003132031200338X>
- [4] M. Halkidi, Y. Batistakis, and M. Vazirgiannis, “On clustering validation techniques,” *Journal of Intelligent Information Systems*, vol. 17, no. 2, pp. 107–145, Dec 2001. [Online]. Available: <https://doi.org/10.1023/A:1012801612483>
- [5] Y. Lei, J. C. Bezdek, S. Romano, N. X. Vinh, J. Chan, and J. Bailey, “Ground truth bias in external cluster validity indices,” *Pattern Recognition*, vol. 65, pp. 58 – 70, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0031320316303910>
- [6] VideoScribe, “VideoScribe - Whiteboard Animation Software | Whiteboard Video Maker,” <https://www.videoscribe.co/>, 2018, [Online; accessed september-2018].
- [7] Doodly, “Doodly - Easily Create Whiteboard Doodle Videos In Minutes!” <https://www.doodly.com/>, 2018, [Online; accessed september-2018].
- [8] Animaker, “Animaker, Crea video-animaciones en la nube gratis,” <https://www.animaker.es>, 2018, [Online; accessed september-2018].



# Competición Vídeo: Inteligencia artificial aplicada al desarrollo de software

Aurora Ramírez Quesada

Dpto. Informática y Análisis Numérico, Universidad de Córdoba

aramirez@uco.es

**Resumen**—Los profesionales de la medicina, las finanzas o la logística han sabido incorporar los avances que ofrece la inteligencia artificial, convirtiéndola en una herramienta de apoyo para la toma de decisiones o la optimización de sus procesos. Normalmente, la creación de estos procesos inteligentes recae en ingenieros informáticos con conocimientos en estas técnicas. Sin embargo, los propios profesionales de la informática también se enfrentan a situaciones en las que la inteligencia artificial puede servir de apoyo para, por ejemplo, acelerar el tiempo de ejecución de los proyectos o mejorar los productos software. El propósito de este vídeo es presentar de manera divulgativa una de las técnicas de inteligencia artificial más conocidas, los algoritmos evolutivos, y cómo estos pueden aplicarse en el ámbito del desarrollo software.

## I. INTRODUCCIÓN

La aplicación de técnicas de inteligencia artificial (IA) al proceso de desarrollo software no se limita a un único tipo de técnica. Si bien se utilizan ya métodos propios del aprendizaje automático o basados en redes bayesianas, la aplicación de técnicas de optimización y búsqueda han despertado un especial interés en los últimos años. La denominada ingeniería del software basada en búsqueda (*Search-based Software Engineering*, SBSE) [1] propone la reformulación de las tareas propias de la ingeniería del software como problemas de optimización, para a continuación abordar su resolución mediante técnicas como las metaheurísticas [2].

Actualmente, es posible encontrar propuestas SBSE para abordar tareas en la mayoría de fases del ciclo de vida del software:

1. Requisitos, con estudios centrados en la selección y priorización de los requisitos a implementar en la siguiente versión del software [3].
2. Análisis y diseño, tanto de sistemas orientados a objetos como basados en servicios [4].
3. Codificación, donde se persigue corregir errores y mejorar aspectos no funcionales del código fuente [5].
4. Pruebas, donde el objetivo es principalmente la generación automática de casos de prueba [6].
5. Mantenimiento, que engloba procesos de modularización y refactorización del código [7].
6. Gestión del proyecto, donde destacan problemas de planificación temporal y de predicción de costes [8].

Desde el punto de vista de las técnicas empleadas, los algoritmos evolutivos son posiblemente los más populares en SBSE [9]. Se trata de técnicas metaheurísticas inspiradas en la teoría de la evolución de Darwin [10]. Un algoritmo evolutivo

realiza un proceso de optimización iterativo, el cual parte de una población de individuos generados de forma aleatoria. Cada individuo representa una solución candidata al problema, cuya calidad es medida por la función de *fitness*. En cada iteración, conocida como generación, algunos individuos son seleccionados para producir nuevas soluciones al problema. En concreto, el proceso más común es aplicar un operador de cruce, que combina las características de pares de soluciones buscando converger hacia la solución óptima. A continuación, se ejecuta un operador de mutación que altera pequeñas partes de una solución a fin de introducir diversidad en el proceso.

A la hora de aplicar un algoritmo evolutivo en el contexto de SBSE, es necesaria la definición de los dos elementos específicos del problema: la representación de las soluciones y la función de fitness [1]. En el primer caso, se suelen emplear las estructuras en forma de vector habituales en los algoritmos evolutivos, aunque también se pueden utilizar codificaciones en forma de árbol, adecuados para representar partes de un código fuente, o estructuras compuestas para problemas que necesitan manejar más información. Respecto a la función de *fitness*, las propuestas SBSE suelen utilizar medidas software para medir la calidad de los artefactos software producidos. Por ejemplo, la generación de casos de prueba se basa en criterios de cobertura del código, mientras que medidas de complejidad, cohesión o acoplamiento son frecuentes en las áreas de diseño y mantenimiento.

Se ha elegido esta temática porque permite mostrar a los profesionales de la informática que pueden beneficiarse de las soluciones que aporta la IA, no solo desarrollarlas. En cuanto a la técnica elegida, los algoritmos evolutivos son una de las técnicas pioneras en el ámbito de las metaheurísticas basadas en población, que a menudo resultan muy llamativas y son relativamente fáciles de entender por su símil biológico. Además, como se mencionó anteriormente, son muy populares en SBSE, por lo que es posible encontrar más ejemplos de aplicación.

## II. DESCRIPCIÓN DEL VÍDEO

El vídeo tiene como principal propósito presentar una visión global de las posibilidades que ofrece la IA a los profesionales software como método de apoyo a la decisión. Es por ello por lo que el vídeo comienza planteando diversas situaciones en las que los ingenieros deberían valorar distintas alternativas antes de elegir la mejor solución. De esta forma se busca hacer ver al espectador la dificultad que conlleva el desarrollo de

software y la variedad de casuísticas para las que la IA puede ser útil. Para mantener una separación clara entre el dominio de aplicación y la técnica de IA empleada, se utilizan colores de fondo diferentes como recurso visual.

Una vez realizada la introducción a la temática, el vídeo entra en una fase más teórica que tiene dos objetivos principales: (1) centrar al espectador en las técnicas de búsqueda, como una de las ramas de la IA; y (2) explicar los fundamentos básicos de los algoritmos evolutivos. En este punto, la mayor parte del vídeo se dedica a explicar el proceso iterativo de búsqueda que efectúa un algoritmo evolutivo. Para ello se introduce un pequeño robot que sirve para representar a la IA como una entidad “tangibile” encargada de realizar los distintos pasos del ciclo evolutivo: generar soluciones, seleccionar las soluciones “padre” mediante torneo, generar soluciones “hijo” aplicando cruce y mutación, y reemplazar parte de la población para la siguiente generación. Dado el carácter teórico de esta parte del vídeo, se ha optado por utilizar diseños basados en pizarras y esquemas, así como fuentes que simulan la escritura manual.

Tras la explicación del proceso evolutivo de forma genérica, el vídeo aborda su adaptación a problemas concretos del ámbito del desarrollo software. Para ello se realiza un recorrido por el ciclo de vida clásico del software, planteando un problema para alguna de sus fases. En concreto, el vídeo retoma las preguntas que se planteaban los personajes al comienzo del mismo, transformándolas en la definición de los siguientes problemas de búsqueda:

- Planificación de proyectos software, cuyo objetivo es asignar tareas al equipo de desarrollo para minimizar el tiempo y coste del proyecto [11]. Este problema permite mostrar un ejemplo de codificación real.
- Diseño orientado a objetos, donde se pueden aplicar algoritmos evolutivos para encontrar la mejor asignación de propiedades y métodos a clases en base a criterios de cohesión y acoplamiento [12]. En este caso, se opta por una representación con vectores enteros.
- Selección de casos de prueba, que consiste en elegir un subconjunto de casos de prueba que alcancen una cobertura del código determinada [13]. Este problema se puede abordar como un problema de codificación binaria.
- Refactorización de código, donde se persigue encontrar una secuencia de operaciones de refactorización que eliminen el mayor número de defectos de diseño posibles [14]. Este ejemplo permite introducir una codificación basada en listas de distinta longitud.

Además de describir brevemente el objetivo que se persigue con la optimización y cómo se puede representar el problema, el vídeo aborda la definición de la función de *fitness* y un ejemplo de posibles operadores de cruce y mutación. De esta forma se consigue mostrar la flexibilidad de los algoritmos evolutivos y la variedad de problemas a los que se puede aplicar.

Finalmente, también se hace una mención a enfoques evolutivos más avanzados que tienen gran aplicabilidad en SBSE, como son los algoritmos multiobjetivo [15], que pueden

optimizar más de una función objetivo, y los modelos interactivos [16], que permiten incorporar la opinión del experto.

### III. HERRAMIENTAS Y MATERIALES

Para la elaboración del vídeo se han utilizado herramientas software gratuitas y, en su mayoría, de código abierto. En primer lugar, la edición del vídeo se ha realizado con Powtoon<sup>1</sup>. Se trata de una aplicación web que permite la creación de vídeos con dibujos animados. Aunque se trata de una aplicación de pago, la versión gratuita ofrece la funcionalidad necesaria para la edición de vídeos de corta duración. Además de los recursos gráficos y sonoros proporcionados por la propia herramienta, el usuario puede incorporar sus propias imágenes, vídeos y audios. Powtoon pone a disposición del usuario una gran variedad de plantillas y ejemplos, que facilitan la creación de escenas más complejas. A su vez, los elementos gráficos (objetos, personajes, rótulos, etc.) están disponibles en diferentes estilos, lo que permite adecuar el contenido a diferentes propósitos y audiencias.

Para complementar el catálogo de imágenes de Powtoon, se han utilizado imágenes con licencia *creative common* disponibles en la plataforma Pixabay<sup>2</sup>. En ella pueden descargarse multitud de imágenes en formato PNG o vectorial de forma gratuita. Cuando ha sido necesario, las imágenes han sido editadas mediante herramientas como Inkscape<sup>3</sup> o Gimp<sup>4</sup>.

### IV. UTILIDAD DIDÁCTICA DEL VÍDEO

El vídeo presentado a la competición puede ser un buen recurso didáctico por varios motivos. En primer lugar, proporciona una introducción ágil y práctica a las técnicas de búsqueda, que suelen formar parte de asignaturas sobre IA. Además, presenta los fundamentos básicos de la que posiblemente es la técnica más estudiada, los algoritmos evolutivos. Gracias a la presentación de varios ejemplos, el vídeo puede servir de complemento a la hora de mostrar ámbitos de aplicación menos conocidos. Igualmente, el vídeo también deja entrever la necesidad de desarrollar modelos más avanzados con los que abordar problemas complejos del mundo real, lo cual puede despertar el interés por estudiarlas en más detalle.

Cabe destacar también el marcado carácter interdisciplinar del vídeo, que lo hace muy interesante para los estudiantes de las distintas ramas de la informática. En este sentido, los estudiantes verán que aprender los fundamentos de la IA les puede ser de utilidad para distintos perfiles, tanto investigadores como profesionales. Esto es especialmente relevante dada la evolución que está sufriendo la informática y la necesidad que tienen las empresas de contar con perfiles interdisciplinares. Finalmente, el vídeo también puede ser utilizado de forma divulgativa fuera de las aulas, por ejemplo, para favorecer la transferencia de conocimiento con empresas.

<sup>1</sup><https://powtoon.com>

<sup>2</sup><https://pixabay.com>

<sup>3</sup><http://inkscape.com>

<sup>4</sup><https://gimp.com>



## V. CONCLUSIONES

El vídeo presentado a la competición CAEPIA'18 muestra de forma amena cómo la inteligencia artificial puede resolver problemáticas que surgen a menudo en el proceso de desarrollo software. La intención de este vídeo ha sido presentar a la IA como un método de apoyo a la decisión, capaz de abordar tareas tan diversas como encontrar la mejor planificación de equipos de desarrollo, seleccionar los requisitos que más beneficio reportarán a la empresa, optimizar el diseño de complejos sistemas informáticos o automatizar su entorno de pruebas. Debido a la limitación temporal, el vídeo se centra únicamente en la aplicación de algoritmos evolutivos, sobre los que se explica su proceso iterativo de búsqueda y cómo sus diferentes elementos se deben adaptar al problema a resolver. Para la realización del vídeo se ha utilizado Powtoon, una potente aplicación web para la creación de vídeos mediante dibujos animados.

A modo de valoración personal, la elaboración de este vídeo ha supuesto una gran oportunidad para dar a conocer un dominio de aplicación de la IA que no es tan popular en entornos académicos y, menos aún, entre los profesionales de la informática. También ha supuesto un ejercicio de reflexión sobre la dificultad a la hora de transmitir conceptos avanzados a una audiencia sin conocimientos profundos de IA y en un tiempo muy limitado. Esto ha requerido buscar el lenguaje apropiado, adaptar los contenidos sin perder rigor, recopilar ejemplos prácticos y ser capaz de explicarlos de forma sencilla, etc.

Finalmente, participar en esta competición también ha permitido a su autora aprender a utilizar herramientas software con gran potencial, como es Powtoon. Las habilidades adquiridas pueden ser de gran utilidad en el futuro para la elaboración de materiales didácticos y divulgativos relacionados con esta temática.

### ENLACE AL VÍDEO

El vídeo se encuentra disponible en el siguiente enlace:  
[https://www.youtube.com/watch?v=vfpY8\\_AEB6A](https://www.youtube.com/watch?v=vfpY8_AEB6A)

### AGRADECIMIENTOS

La autora desea expresar su agradecimiento a José Raúl Romero por sus ideas y comentarios sobre las primeras versiones del vídeo.

### REFERENCIAS

- [1] M. Harman, S. A. Mansouri, and Y. Zhang, "Search Based Software Engineering: Trends, Techniques and Applications," *ACM Computing Surveys*, vol. 45, no. 1, pp. 11:1–61, 2012.
- [2] I. Boussaïd, J. Lepagnot, and P. Siarry, "A survey on optimization metaheuristics," *Information Sciences*, vol. 237, pp. 82–117, 2013.
- [3] A. M. Pitangueira, R. S. P. Maciel, and M. Barros, "Software requirements selection and prioritization using SBSE approaches: A systematic review and mapping of the literature," *Journal of Systems and Software*, vol. 103, pp. 267–280, 2015.
- [4] O. Riih a, "A survey on search-based software design," *Computer Science Review*, vol. 4, no. 4, pp. 203–249, 2010.
- [5] J. Petke, S. O. Haraldsson, M. Harman, W. B. Langdon, D. R. White, and J. R. Woodward, "Genetic Improvement of Software: A Comprehensive Survey," *IEEE Transactions on Evolutionary Computation*, vol. 22, no. 3, pp. 415–432, 2018.
- [6] P. McMinn, "Search-based software test data generation: A survey," *Software Testing Verification and Reliability*, vol. 14, no. 2, pp. 105–156, 2004.
- [7] T. Mariani and S. R. Vergilio, "A systematic review on search-based refactoring," *Information and Software Technology*, vol. 83, pp. 14–34, 2017.
- [8] F. Ferruci, M. Harman, and F. Sarro, "Search-Based Software Project Management," in *Software Project Management in a Changing World*, pp. 373–399, Springer-Verlag Berlin Heidelberg, 2014.
- [9] M. Harman, "Software Engineering Meets Evolutionary Computation," *IEEE Software*, no. October, pp. 31–39, 2011.
- [10] A. E. Eiben and J. E. Smith, *Introduction to Evolutionary Computing*. Springer-Verlag Berlin Heidelberg, 2nd ed., 2015.
- [11] E. Alba and J. F. Chicano, "Software project management with GAs," *Information Sciences*, vol. 177, no. 11, pp. 2380–2401, 2007.
- [12] M. Bowman, L. C. Briand, and Y. Labiche, "Solving the class responsibility assignment problem in object-oriented analysis with multi-objective genetic algorithms," *IEEE Transactions on Software Engineering*, vol. 36, no. 6, pp. 817–837, 2010.
- [13] L. S. de Souza, R. B. Prud ncio, F. d. A. Barros, and E. H. d. S. Aranha, "Search based constrained test case selection using execution effort," *Expert Systems with Applications*, vol. 40, no. 12, pp. 4887–4896, 2013.
- [14] A. Ouni, M. Kessentini, H. Sahraoui, and M. Boukadoum, "Maintainability defects detection and correction: A multi-objective approach," *Automated Software Engineering*, vol. 20, no. 1, pp. 47–79, 2013.
- [15] A. S. Sayyad and H. Ammar, "Pareto-optimal search-based software engineering (POSBSE): A literature survey," in *Proceedings of the 2nd International Workshop on Realizing Artificial Intelligence Synergies in Software Engineering (RAISE)*, pp. 21–27, 2013.
- [16] A. Ram rez, J. R. Romero, and C. Simons, "A Systematic Review of Interaction in Search-Based Software Engineering," *IEEE Transactions on Software Engineering*, 2018. In press.

# Video Competition: Solving Smart Mobility Problems Using Bio-inspired Techniques

1<sup>st</sup> Daniel H. Stolfi

*Departamento de Lenguajes y Ciencias de la Computación*  
*University of Malaga*  
Malaga, Spain  
dhstolfi@lcc.uma.es

2<sup>nd</sup> Enrique Alba

*Departamento de Lenguajes y Ciencias de la Computación*  
*University of Malaga*  
Malaga, Spain  
eat@lcc.uma.es

## I. TOOLS AND ASSETS

This video was made using Open Source tools such as Ubuntu, Kdenlive, Audacity, Gimp, LibreOffice, and the traffic microsimulator SUMO. Graphic resources were obtained from OpenStreetMap, Google Earth, Bing Maps, and Pixabay. Finally, sound effects were downloaded from Free Sound Clips. The selected soundtrack is Chill Police by Anttis Instrumentals. The rest of pictures and sounds were created by the authors. Link: <https://youtu.be/ssE0RDitQvY>

## II. A.I. TECHNIQUE

We have chosen our epiGenetic Algorithm (epiGA) [5] as an A.I. technique to optimize our Yellow Swarm architecture [3], [4], [6] to obtain the optimal time slots for each sign and LED panel with the aim of reducing travel times, greenhouse gas emissions, and fuel consumption in the city of Malaga (Spain).

Yellow Swarm suggests possible detours to vehicles by showing different cyclical indications to drivers using LED panels. It has two stages: The Offline stage in which the system is configured, and the Online stage in which drivers are informed about the suggested detours. In the Offline stage, our epiGA analyzes different scenarios (traffic distributions) of our case studies, using the SUMO traffic simulator [1] which is controlled by the TraCI module [7], in order to implement the decisions that drivers make during their journey. The urban maps used to build the case studies have been imported from OpenStreetMap [2] so that we can test our system in realistic city districts, including traffic lights, roundabouts, etc. The training carried out in this phase results in the configuration of the LED panels to be used in the next stage.

In the Online stage, the LED panels show the different detour options to drivers depending on the time slots calculated in the previous stage, using the Panel Manager. The possible signs are: go straight on, turn left, and turn right. However, their availability depends on the type of junction the vehicles are approaching, i.e. the possible detour options, and the street where the panel is placed. The first sign is visible during a previously calculated time interval, after that the next sign in the sequence will be presented to the drivers. Once the cycle has finished it again starts with the first sign of the sequence.

By using this strategy, Yellow Swarm is able to prevent possible traffic jams in the city as well as improve the use

of most of the available secondary streets. Furthermore, as it uses LED panels, no personal devices (GPS navigators, mobile phones, etc.) are needed. Yellow Swarm also promotes road safety as drivers do not have to lose eye contact with the street while driving.

The epiGenetic Algorithm (epiGA) [5] consists of a set of strategies, based on evolutionary computation, inspired in nature, especially in epigenetics, with the aim of solving complex combinatorial problems. DNA and histones are collapsed to form nucleosomes, and this affects the gene replication during reproduction, while the epigenetic mechanisms modify the gene expression through methylation. We use this bio-inspired model to build the operators of our algorithm.

## III. NARRATIVE RESOURCES

The video was intended to be understood by everyone, so general concepts were presented and at the end of it, a set of references are given in order to provide more technical information. The first part is meant to present the road traffic in the city and its negative consequences as a real world problem to be solved, then our smart mobility solution (Yellow Swarm) is explained. After that, the A.I. technique (epiGenetic Algorithm) takes over to answer one research question: How the Yellow Swarms time slots can be optimally calculated? Finally, the improvements achieved, i.e. shorter travel times, less emissions and fuel consumption, are shown in a bar graph.

## IV. DISCUSSION

We have used several sound effects, animations, and transitions to make the video more dynamic and keep the viewers engaged. Our goal here is to present our smart mobility solution in which an A.I. technique is used to make it effective and efficient. Viewers should be able to understand our proposal and learn how new algorithms inspired in nature can be used to improve their lives. Additionally, it may be useful to show that Artificial Intelligence is not *Skynet*, i.e. that it is not here to end with humans, but to help us.

## ACKNOWLEDGMENT

This research has been partially funded by the Spanish MINECO and FEDER projects TIN2014-57341-R, TIN2016-81766-REDT, and TIN2017-88213-R. University of Malaga,



Andalucía TECH. Daniel H. Stolfi is supported by a FPU grant (FPU13/00954) from the Spanish MECD.

#### REFERENCES

- [1] Krajzewicz, D., Erdmann, J., Behrisch, M., Bieker, L.: Recent Development and Applications of SUMO - Simulation of Urban MObility. *International Journal On Advances in Systems and Measurements* **5**(3), 128–138 (2012)
- [2] OpenStreetMap Foundation: OpenStreetMap (2018), <http://www.openstreetmap.org/>
- [3] Stolfi, D.H., Alba, E.: Smart Mobility Policies with Evolutionary Algorithms: The Adapting Info Panel Case. In: Proceedings of the 2015 Annual Conference on Genetic and Evolutionary Computation. pp. 1287–1294. GECCO '15, ACM, New York, NY, USA (2015)
- [4] Stolfi, D.H., Alba, E.: Un Algoritmo Evolutivo para la Reducción de Tiempos de Viaje y Emisiones Utilizando Paneles LED. In: X Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados. pp. 27–34. MAEB 2015, Mérida - Almendralejo (2015)
- [5] Stolfi, D.H., Alba, E.: Epigenetic algorithms: A New way of building GAS based on epigenetics. *Information Sciences* **424**(Supplement C), 250–272 (2018)
- [6] Stolfi, D.H., Armas, R., Alba, E., Aguirre, H., Tanaka, K.: Fine Tuning of Traffic in Our Cities with Smart Panels: The Quito City Case Study. In: Proceedings of the Genetic and Evolutionary Computation Conference 2016. pp. 1013–1019. GECCO '16, ACM, New York, NY, USA (2016)
- [7] Wegener, A., Piórkowski, M.: TraCI: An Interface for Coupling Road Traffic and Network Simulators. In: Proceedings of the 11th Communications and Networking Simulation Symposium. pp. 155–163. CNS '08, ACM, New York, NY, USA (2008)