

Descubrimiento de subgrupos mediante sistemas difusos evolutivos

Cristóbal J. Carmona
 Departamento de Informática
 Universidad de Jaén
 Jaén, Spain
 ccarmona@ujaen.es

Resumen—El descubrimiento de subgrupos es una técnica de minería de datos basada en aprendizaje supervisado para la descripción de relaciones novedosas o atípicas con respecto a una variable de interés para el usuario. A lo largo de la bibliografía se han presentado un amplio número de algoritmos para esta tarea, que a su vez han sido aplicados para resolver determinados problemas del mundo real.

En este trabajo se presentan los sistemas difusos evolutivos desarrollados hasta el momento para la tarea de descubrimiento de subgrupos. Para ello, se muestran las principales propiedades y características de estos sistemas en general, y en particular las propiedades de los algoritmos SDIGA, MESDIF y NMEEF-SD. Además, se pueden observar los principales problemas del mundo real resueltos mediante este tipo de sistemas.

Index Terms—Descubrimiento de Subgrupos, Sistemas Difusos Evolutivos, NMEEF-SD, MESDIF, SDIGA.

I. INTRODUCCIÓN

La minería de datos se define como [1]: “La utilización de algoritmos para generar una enumeración de patrones a partir de los datos”. Es una etapa que forma parte del proceso de extracción de conocimiento en grandes bases de datos y se centra en desarrollar y aplicar algoritmos que, bajo limitaciones aceptables de eficiencia computacional obtengan patrones sobre los datos. El espacio de búsqueda de los patrones suele ser muy grande, y la extracción de patrones supone realizar algún tipo de búsqueda sobre este espacio. Actualmente, existen limitaciones tanto computacionales como físicas y por tanto es necesario restringir este espacio a unos límites concretos.

Dentro de la minería de datos se pueden distinguir dos objetivos bien diferenciados:

- **Predicción.** El sistema busca patrones para predecir un comportamiento futuro. Los modelos desarrollados dentro de este objetivo están basados en aprendizaje supervisado. Entre las tareas predictivas se puede encontrar por ejemplo clasificación [2], regresión [2] o análisis de series temporales [3].
- **Descripción.** El sistema busca patrones para presentarlos a un experto en una forma comprensible para él, y que describen y aportan información de interés sobre el problema y el modelo que subyace bajo los datos. Los modelos desarrollados en este sistema se basan en aprendizaje no supervisado. Entre las tareas descriptivas

se pueden encontrar agrupamiento [4], sumarización [5] o asociación [6] entre otras.

A pesar de existir una clara distinción entre las técnicas dependiendo de los objetivos que pretenden abordar, en la actualidad existen un conjunto de técnicas que se encuentran a medio camino entre las técnicas predictivas y las descriptivas, agrupadas bajo el nombre descubrimiento de reglas descriptivas basadas en aprendizaje supervisado [7], que intentan obtener reglas o conjuntos de items de una categoría o clase prefijada para describir información significativa y relevante del conjunto de datos. Su principal objetivo no es clasificar nuevas instancias, sino comprender o encontrar fenómenos subyacentes, es decir, encontrar información desconocida u oculta difícil de descubrir por los expertos sobre el valor de una clase prefijada o variable de interés.

El descubrimiento de subgrupos es un tipo de inducción descriptiva que ha recibido últimamente mucha atención por parte de los investigadores. En el descubrimiento de subgrupos se pretenden generar modelos basados en reglas cuya finalidad es descriptiva, empleando una perspectiva predictiva para obtenerlos [8]. Se trata por tanto de una tarea con objetivos básicamente descriptivos que incluye características de la inducción predictiva.

En este trabajo se presenta en la Sección II las propiedades más destacadas del descubrimiento de subgrupos, en la Sección III se muestran los sistemas evolutivos difusos para descubrimiento de subgrupos desarrollados hasta el momento, y en la sección IV se indican aplicaciones al mundo real resueltas mediante estos algoritmos. Finalmente, en la sección V se muestran las principales conclusiones del trabajo.

II. DESCUBRIMIENTO DE SUBGRUPOS

El concepto de descubrimiento de subgrupos fue inicialmente introducido por Kloesgen [9] y Wrobel [10], y definido más formalmente por Siebes [11] pero empleando el nombre de *Data Surveying* para el descubrimiento de subgrupos interesantes. El concepto de descubrimiento de subgrupos se puede definir como [12]:

En el descubrimiento de subgrupos, asumimos una población de individuos dada (objetos, clientes, ...) y una propiedad de estos individuos en la que

estemos interesados. La tarea del descubrimiento de subgrupos es entonces descubrir los subgrupos de la población que son estadísticamente “más interesantes”, es decir, individuos que sean tan grandes como sea posible y tenga una distribución estadística lo más atípica posible, con respecto a una propiedad de interés.

El descubrimiento de subgrupos intenta buscar relaciones entre diferentes propiedades o variables de un conjunto con respecto a una variable objetivo. Debido a que el descubrimiento de subgrupos está centrado en la extracción de relaciones con características interesantes, no es necesario obtener relaciones completas sino que suele ser suficiente con relaciones parciales. Estas relaciones son descritas en forma de reglas individuales.

Así, una regla (R), que consiste de una descripción de un subgrupo inducido, puede ser definida formalmente como [13], [14]:

$$R : Cond \rightarrow VarObj$$

donde $VarObj$ es el valor de la variable de interés o variable objetivo para la tarea de descubrimiento de subgrupos (puede aparecer además en la bibliografía específica como *Clase*), y $Cond$ es comúnmente una conjunción de funciones (pares atributo-valor) que es capaz de describir una distribución estadística inusual con respecto a la variable objetivo.

Esta técnica se encuentra a medio camino entre la inducción predictiva y descriptiva, y su objetivo es generar de forma sencilla e interpretable subgrupos para describir relaciones entre variables independientes y un cierto valor de la variable objetivo.




Figura 1. Representación de un subgrupo para la clase x

En la figura 1 se representa una regla de descubrimiento de subgrupos, donde se pueden observar dos valores para la variable objetivo ($VarObj = \{x \text{ y } o\}$). En la figura se representa un subgrupo correspondiente al valor x , donde el subgrupo o regla cubre un alto número de valores de la variable objetivo con una función sencilla como es un círculo. Sin

embargo, el grupo no cubre todos los ejemplos para el valor x de la variable objetivo, incluso no todos los ejemplos son cubiertos correctamente, pero la forma de la función es simple y muy interpretable. De esta forma, el algoritmo consigue una reducción de la complejidad. Además, en este ejemplo el índice de verdaderos positivos para el valor es alto, con un valor del 75 %.

Por ejemplo, sea D un conjunto de datos con tres variables:

- $Edad = \{Menor \text{ de } 25, 25 \text{ a } 60, \text{ Más de } 60\}$
- $Sexo = \{M, F\}$
- $País = \{España, USA, Francia, Alemania\}$

considerando además la variable de interés $Colesterol = \{Bajo, Normal, Alto\}$. Algunos ejemplos de reglas que contienen descripciones de subgrupos pueden ser:

$$R_1 : (Edad = Menor \text{ que } 25 \text{ Y } País = España) \rightarrow Colesterol = Alto$$

$$R_2 : (Edad = Más \text{ que } 60 \text{ Y } Sexo = F) \rightarrow Colesterol = Bajo$$

donde la regla R_1 representa un subgrupo de españoles con menos de 25 años, en los cuales se puede observar una probabilidad muy alta de que tengan el colesterol alto. Sin embargo, la regla R_2 representa a un grupo de mujeres con edad superior a 60 años, donde independientemente del país, se puede observar una probabilidad alta de que tengan colesterol bajo. Como se puede observar en ambas reglas, el descubrimiento de subgrupos intenta describir patrones con una distribución inusual con respecto a la variable objetivo.

A lo largo de la bibliografía se pueden encontrar una amplia variedad de algoritmos implementados para esta tarea, con una gran aplicabilidad de los mismos en problemas del mundo real. Una reciente revisión del descubrimiento de subgrupos se puede observar en [15].

II-A. Diferencias entre el descubrimiento de subgrupos y modelos para clasificación

El descubrimiento de subgrupos [9] es una técnica de extracción de patrones con respecto a una propiedad de interés o variable objetivo de los datos. Esta técnica se encuentra a medio camino entre la inducción predictiva y descriptiva, y su objetivo es generar de forma sencilla e interpretable subgrupos para describir relaciones entre variables independientes y un cierto valor de la variable objetivo.

Así, la tarea de descubrimiento de subgrupos se diferencia de las técnicas de clasificación básicamente porque el descubrimiento de subgrupos intenta describir conocimiento para los datos mientras un clasificador intenta predecir nuevos datos que se deseen incorporar. A continuación, en la tabla I se pueden observar las principales diferencias entre clasificación y descubrimiento de subgrupos.

Tabla I
CLASIFICACIÓN CONTRA DESCUBRIMIENTO DE SUBGRUPOS

Objetivo	Clasificación	Descubrimiento de subgrupos
Inducción	Predictiva	Descriptiva
Salida	Conjuntos de reglas de clasificación	Reglas individuales para describir subgrupos
Propósito	Aprender un modelo para clasificación o predicción	Encontrar patrones interpretables e interesantes con respecto a una variable objetivo
Reglas	Dependientes	Individuales

Como se resume en la tabla I, el modelo obtenido por un algoritmo de descubrimiento de subgrupos es un modelo sencillo formado por reglas individuales, interpretables y únicas, mientras que el obtenido por un clasificador es preciso, donde las reglas se analizan en conjunto. Sin embargo, en un problema de descubrimiento de subgrupos se pueden obtener subgrupos más específicos o genéricos, dependiendo de las propiedades del problema a estudiar. Por ejemplo, en la figura 2 se pueden observar distintos subgrupos obtenidos para un problema específico. En este caso, el *subgrupo A* representa un subgrupo más específico dentro del problema pues cubre únicamente dos ejemplos para la variable objetivo x , el *subgrupo B* en este caso cubre un ejemplo más. Ambos subgrupos tienen una calidad muy alta, ya que todos los ejemplos cubiertos están correctamente descritos. Por otro lado, se puede observar un subgrupo más genérico que cubre a todos los ejemplos de la variable objetivo, el *subgrupo C*. En este caso también se cubren dos ejemplos para otro valor de la variable objetivo o , lo que decrementa la calidad del subgrupo.




Figura 2. Representación de diferentes subgrupos

Como se puede observar en la figura 2, ambas dimensiones de generalidad y precisión tienen propiedades opuestas completamente, ya que por regla general al aumentar una se decrementa la otra dimensión. Es por ello, que un algoritmo de descubrimiento de subgrupos necesite obtener subgrupos de calidad y con una buena relación entre ambas dimensiones.

II-B. Principales elementos de los modelos de descubrimiento de subgrupos

Existen diferentes elementos a especificar en el diseño de un algoritmo de descubrimiento de subgrupos. Estos elementos se definen a continuación [16]:

- *Tipo de la variable objetivo.* Se pueden encontrar diferentes tipos de variable objetivo: binaria, nominal o numérica. Para cada una de ellas se pueden aplicar diferentes análisis considerando el tipo de la variable objetivo.
- *Lenguaje de descripción.* La representación de los subgrupos debe ser adecuada para obtener reglas interesantes. Las reglas deben ser sencillas y por ello se suelen representar mediante pares atributo-valor generalmente en forma normal conjuntiva o disyuntiva. Además, los valores se pueden representar mediante valores positivos y/o negativos, mediante lógica difusa, o mediante el uso de desigualdades o igualdades, entre otros.
- *Medidas de calidad.* Éstas son un factor clave para la extracción de conocimiento ya que el interés del conocimiento extraído depende directamente de ellas. Además, las medidas de calidad proporcionan al experto la calidad e importancia de los subgrupos obtenidos. Se han presentado diferentes medidas de calidad en la bibliografía especializada [9], [14], [17], [18]. Además, en [15] se presenta una revisión sobre el uso de las diferentes medidas de calidad utilizadas a lo largo de la bibliografía agrupándolas en diferentes grupos dependiendo de sus objetivos.
- *Estrategia de búsqueda.* Este elemento es muy importante, ya que la dimensión del espacio de búsqueda tiene una relación exponencial respecto al número de propiedades y valores considerados. Hasta el momento se han utilizado diferentes estrategias, por ejemplo *beam search*, algoritmos evolutivos, búsqueda en espacios multirelacionales, etc.

III. LOS SISTEMAS EVOLUTIVOS DIFUSOS EN EL DESCUBRIMIENTO DE SUBGRUPOS

En primer lugar se presentan los sistemas evolutivos difusos, y a continuación los sistemas evolutivos difusos presentados hasta el momento para la tarea de descubrimiento de subgrupos.

III-A. Sistemas evolutivos difusos

Un sistema evolutivo difuso es básicamente un sistema difuso incrementado por un proceso de aprendizaje basado en computación evolutivo [19]. La lógica difusa permite modelar conocimiento impreciso y cuantitativo, así como transmitir y manejar incertidumbre y soportar, en una extensión razonable, el razonamiento humano de una forma natural. Desde que Zadeh propuso la teoría de conjuntos difusos [20] y el concepto de variable lingüística [21], se ha aplicado en múltiples áreas de investigación, fundamentalmente por su cercanía al

razonamiento humano y por proporcionar una forma efectiva para capturar la naturaleza aproximada e inexacta del mundo real. Además, es una herramienta que permite representar conceptos de forma expresiva y fácilmente entendible para el usuario, es decir, de forma lingüística. Por tanto, esta herramienta se sitúa en el nivel de representación y se puede utilizar en combinación con otras técnicas.

Por otro lado, los algoritmos evolutivos son algoritmos estocásticos de optimización y búsqueda inspirados en los procesos de evolución natural y fueron definidos inicialmente por Holland [22]. Dentro de la computación evolutiva se incluye a los algoritmos genéticos, programación genética, estrategias evolutivas, entre otros algoritmos evolutivos [23].

Por regla general, este tipo de sistemas consideran la estructura de un modelo en la forma de reglas difusas y se denominan sistemas basados en reglas difusas, los cuáles han demostrado su habilidad con respecto a diferentes problemas como problemas de control, modelado, clasificación o minería de datos en un amplio número de aplicaciones. Una de las principales ventajas de los sistemas basados en reglas difusas es la obtención de una representación comprensible del conocimiento extraído siendo además una herramienta útil para el procesamiento de las variables continuas.

Dentro de los sistemas evolutivos difusos para la resolución de problemas de descubrimiento de subgrupos se encuentran diferentes enfoques con diferentes propiedades. Estos algoritmos son descritos a continuación.

III-B. Algoritmos evolutivos para extracción de subgrupos

Uno de los tipos de algoritmos más empleados son los algoritmos evolutivos, y concretamente los algoritmos genéticos, inspirados en la evolución natural [22]. La heurística empleada por este tipo de algoritmos está definida por una función de calidad que determina que individuos (reglas en este caso) serán seleccionados para formar parte de las nuevas poblaciones en procesos competitivos. Esto hace que los algoritmos evolutivos sean muy útiles para la tarea de descubrimiento de subgrupos. A continuación se detallan los algoritmos evolutivos para descubrimiento de subgrupos presentados en la bibliografía:

- SDIGA [25] es un algoritmo evolutivo para inducción de reglas difusas. Utiliza como medidas de calidad adaptaciones de medidas empleadas en algoritmos de inducción de reglas de asociación como confianza y soporte, y además puede emplear medidas como interés, atipicidad, entre otras. El algoritmo evalúa la calidad de las reglas por medio de una función de agregación de varios objetivos. En [26] se puede observar un análisis de diversas combinaciones de medidas de calidad. SDIGA utiliza reglas lingüísticas como lenguaje de descripción para especificar los subgrupos [27]. Este algoritmo está implementado en la herramienta KEEL [28], [29].
- MESDIF [30], [31] es un algoritmo genético multi-objetivo para la extracción de reglas difusas para describir subgrupos. El algoritmo extrae un número variable de

reglas diferentes para expresar información de una variable objetivo. La búsqueda está basada en el algoritmo SPEA-2 [32], y emplea el concepto de elitismo y obtiene las soluciones óptimas del frente de Pareto [33]. Puede utilizar varias medidas para evaluar las reglas obtenidas como confianza, soporte, atipicidad, relevancia, entre otras. Este algoritmo está implementado en la herramienta KEEL [28], [29].

- NMEEF-SD [34] es un sistema evolutivo difuso cuyo objetivo es extraer reglas difusas y/o nítidas para descubrimiento de subgrupos dependiendo del tipo de variables presentes en el problema. NMEEF-SD se basa en un enfoque multi-objetivo cuya estrategia de búsqueda se centra en el enfoque del algoritmo NSGA-II [35], que es un enfoque de ordenación no-dominada con elitismo. Este algoritmo utiliza operadores específicos para promocionar la extracción de reglas simples, interpretables y con alta calidad. Permite utilizar un amplio número de medidas de calidad dentro del enfoque evolutivo, incluyendo por ejemplo la confianza, soporte, sensibilidad, relevancia y atipicidad. Este algoritmo está implementado en la herramienta KEEL [28], [29].

Estos algoritmos proporcionan herramientas novedosas y útiles para análisis de patrones y para extracción de nuevos tipos de información útil.

IV. APLICACIONES A PROBLEMAS DEL MUNDO REAL CON SISTEMAS EVOLUTIVOS DIFUSOS MEDIANTE DESCUBRIMIENTO DE SUBGRUPOS

En la bibliografía especializada se puede encontrar un amplio rango de contribuciones relacionadas con diferentes campos de estudio analizadas mediante la tarea de descubrimiento de subgrupos con sistemas evolutivos difusos. En la tabla II se resumen las aplicaciones reales abordadas mediante este tipo de algoritmos.

Tabla II
PROBLEMAS REALES RESUELTOS MEDIANTE SISTEMAS EVOLUTIVOS DIFUSOS PARA DESCUBRIMIENTO DE SUBGRUPOS

<i>Campo</i>	<i>Aplicación</i>	<i>Referencias</i>
Medicina	Emergencias psiquiátricas	[36]
Marketing	Comercial	[14], [37]
Aprendizaje	e-aprendizaje	[38], [39]

Tal y como muestra esta tabla, el descubrimiento de subgrupos está teniendo una variada aplicabilidad a problemas del mundo real dentro de la comunidad científica, ya que esta técnica consigue obtener modelos muy descriptivos con respecto a una variable objetivo, y con una alta interpretabilidad. Estas propiedades la hacen una tarea de minería de datos muy interesante para los expertos.

En particular para cada uno de estos estudios:

- En el problema de medicina [36] se presentó un problema de emergencias psiquiátricas realizando una comparación entre los algoritmos SDIGA, MESDIF y CN2-SD. El objetivo fue caracterizar subgrupos de pacientes que tienden a visitar el servicio de emergencias psiquiátricas en determinadas franjas horarias con el objetivo de mejorar la organización del servicio.

El análisis realizado por los expertos sobre las reglas obtenidas permitió establecer algunos comentarios respecto a la relación entre los datos disponibles de los pacientes del servicio de emergencias psiquiátricas y el periodo de llegada al servicio. En concreto, las reglas obtenidas muestran que algunas de las variables pueden tener más influencia en el tiempo de llegada de los pacientes que otra como por ejemplo los comportamientos autolíticos de los pacientes. Además, la relación entre las horas solares, días en fin de semana, estacionalidad, condiciones climáticas y desórdenes psiquiátricos ha sido un tema constante de especulación debido a los resultados contradictorios. Para concluir los expertos resaltaron que los resultados obtenidos por los algoritmos no solo coinciden con los informes encontrados en [40], sino que además permiten caracterizar determinados pacientes.

- La planificación de ferias se estudió con algoritmos evolutivos para el descubrimiento de subgrupos en [25], [30]. El objetivo era obtener subgrupos para la planificación de posibles futuras ferias. Las ferias se consideran instrumentos muy importantes por los empresarios para lograr los objetivos comerciales.

En estos problemas los expertos en marketing indicaron la utilidad del descubrimiento de subgrupos pues es capaz de describir relaciones atípicas con respecto a una variable de interés como es la eficiencia de los expositores. En particular destacaron a través del análisis de los subgrupos obtenidos que:

- Los expositores que provenían de la zona sur de España obtuvieron resultados malos considerando que la feria se celebró en el norte de España.
- Los expositores con mejores resultados provenían del centro, destacando que no enviaron folletos de agradecimiento a ninguno de sus contactos.
- Los expositores con niveles salariales muy altos y muy pequeños obtuvieron buenos resultados. Esto se debe a que los primeros preparan la feria muy bien gracias a los recursos con los que cuentan, y los últimos mejoran sus expectativas iniciales.

- En [38], [39] se puede observar la aplicación y comparación de diferentes algoritmos de descubrimiento de subgrupos en un sistema de enseñanza virtual. El diseño de sistemas educativos basados en la web han tenido un alto crecimiento en los últimos años. Estos sistemas acumulan una gran cantidad de información relacionada con el comportamiento de los estudiantes. Debido a esta gran cantidad de información que generan estos sistemas es necesario aplicar herramientas de minería de datos que

ayuden a los expertos [41].

En la enseñanza presencial un profesor es capaz de reconocer a través de la propia interacción con los alumnos, las dificultades y/o facilidades que los mismos están teniendo con sus cursos, y de esta forma realizar un auto-aprendizaje para mejorar en años sucesivos los cursos, y conseguir así una mejora en las notas académicas obtenidas por sus alumnos. Sin embargo, en una plataforma de enseñanza virtual es muy complejo realizar un profundo análisis por parte del profesor con respecto a la utilización de recursos, programación de actividades, cuestionarios, etc.

En ambos artículos se emplearon datos obtenidos por el sistema de la Universidad de Córdoba, con el objetivo de encontrar relaciones entre la utilización de la plataforma y la nota obtenida por los alumnos. En particular, en [39] se aplicó una primera aproximación del algoritmo SDIGA (basado en precisión [39], cobertura y relevancia. En [38] se realizó una comparación con una versión diferente de SDIGA (basada en atipicidad y sensibilidad), Apriori-SD, CN2-SD y MESDIF. Ambos estudios demuestran que el descubrimiento de subgrupos, y en concreto los sistemas evolutivos difusos pueden obtener resultados de alta calidad para describir relaciones interesantes y atípicas con respecto a una variable de interés, y así ayudar a los profesores a mejorar y optimizar los recursos empleados por los mismos en sus cursos virtuales para mejorar las notas obtenidas por los alumnos.

V. CONCLUSIONES

En este trabajo se presenta un problema de extracción de conocimiento descriptivo bajo aprendizaje supervisado mediante descubrimiento de subgrupos, una técnica que se encuadra dentro de un nuevo grupo de técnicas capaces de proporcionar a los expertos conocimiento novedoso con respecto a una variable de interés.

Los algoritmos de descubrimiento de subgrupos extraen modelos sencillos, con pocas reglas y un bajo número de variables, para una variable objetivo. El uso de reglas difusas mediante sistemas evolutivos difusos para el descubrimiento de subgrupos facilita el análisis a los expertos, ya que se emplean etiquetas lingüísticas en todas las variables del conjunto de datos, lo que proporciona a los expertos un conocimiento más cercano al razonamiento humano, empleando valores del lenguaje natural en vez de intervalos numéricos. Además, la utilización de los algoritmos genéticos ofrecen un conjunto de ventajas para la extracción de conocimiento en problemas caracterizados por la buena interacción con los atributos y la habilidad para recorrer el espacio de búsqueda.

La obtención de reglas interesantes y atípicas por los algoritmos de descubrimiento de subgrupos es otra ventaja proporcionada por la aplicación de algoritmos como SDIGA, MESDIF y NMEEF-SD, tal y como se puede observar en las distintas aplicaciones a problemas reales que se han realizado con estos algoritmos a lo largo de la bibliografía.

AGRADECIMIENTOS

Este trabajo ha sido subvencionado por el Ministerio de Educación, Política Social y Deportes de España bajo el proyecto TIN-2008-06681-C06-02, Fondos FEDER y por el Plan de Investigación de Andalucía por el proyecto TIC-3928, Fondos FEDER.

REFERENCIAS

- [1] U. M. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "From data mining to knowledge discovery: an overview," in *Advances in knowledge discovery and data mining*. AAAI/MIT Press, 1996, pp. 1–34.
- [2] V. Cherkassky and F. Mulier, *Learning from Data. Concepts, Theory and Methods*, 2nd ed. IEEE Press, 2007.
- [3] G. Box, G. Jenkins, and G. Reinsel, *Time series analysis: forecasting and control*, 4th ed. Wiley, 2008.
- [4] J. B. MacQueen, "Some Methods for classification and Analysis of Multivariate Observations," in *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*, vol. 1, 1967, pp. 281–297.
- [5] R. Zembowicz and J. M. Zytow, "From Contingency Tables to Various Forms of Knowledge in Databases," in *Advances in Knowledge Discovery and Data Mining*. AAAI/MIT Press, 1996, pp. 329–349.
- [6] R. Agrawal, T. Imielinski, and A. Swami, "Mining association rules between sets of items in large databases," in *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*. ACM Press, 1993, pp. 207–216.
- [7] P. Kralj-Novak, N. Lavrac, and G. I. Webb, "Supervised Descriptive Rule Discovery: A Unifying Survey of Constraint Set, Emerging Pattern and Subgroup Mining," *Journal of Machine Learning Research*, vol. 10, pp. 377–403, 2009.
- [8] N. Lavrac, B. Kavsek, P. A. Flach, and L. Todorovski, "Subgroup Discovery with CN2-SD," *Journal of Machine Learning Research*, vol. 5, pp. 153–188, 2004.
- [9] W. Kloesgen, "Explora: A Multipattern and Multistrategy Discovery Assistant," in *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence, 1996, pp. 249–271.
- [10] S. Wrobel, "An Algorithm for Multi-relational Discovery of Subgroups," in *Proceedings of the 1st European Symposium on Principles of Data Mining and Knowledge Discovery*, ser. LNAI, vol. 1263. Springer, 1997, pp. 78–87.
- [11] A. Siebes, "Data Surveying: Foundations of an Inductive Query Language," in *Proceedings of the 1st International Conference on Knowledge Discovery and Data Mining*. AAAI Press, 1995, pp. 269–274.
- [12] S. Wrobel, *Inductive logic programming for knowledge discovery in databases*. Springer, 2001, ch. Relational Data Mining, pp. 74–101.
- [13] D. Gamberger and N. Lavrac, "Expert-Guided Subgroup Discovery: Methodology and Application," *Journal Artificial Intelligence Research*, vol. 17, pp. 501–527, 2002.
- [14] N. Lavrac, B. Cestnik, D. Gamberger, and P. A. Flach, "Decision Support Through Subgroup Discovery: Three Case Studies and the Lessons Learned," *Machine Learning*, vol. 57, no. 1-2, pp. 115–143, 2004.
- [15] F. Herrera, C. J. Carmona, P. González, and M. J. del Jesus, "An overview on Subgroup Discovery: Foundations and Applications," *Knowledge and Information Systems*, vol. In press, 2011.
- [16] M. Atzmueller, F. Puppe, and H. P. Buscher, "Towards Knowledge-Intensive Subgroup Discovery," in *Proceedings of the Lernen - Wissensentdeckung - Adaptivität - Fachgruppe Maschinelles Lernen*, 2004, pp. 111–117.
- [17] D. Gamberger and N. Lavrac, "Active subgroup mining: a case study in coronary heart disease risk group detection," *Artificial Intelligence in Medicine*, vol. 28, no. 1, pp. 27–57, 2003.
- [18] W. Kloesgen and J. Zytow, *Handbook of Data Mining and Knowledge Discovery*, W. Kloesgen, Ed. Oxford, 2002.
- [19] F. Herrera, "Genetic fuzzy systems: taxonomy, current research trends and prospects," *Evolutionary Intelligence*, vol. 1, pp. 27–46, 2008.
- [20] L. A. Zadeh, "Information Control," *Fuzzy sets*, vol. 8, pp. 338–353, 1965.
- [21] L. A. Zadeh, "The concept of a linguistic variable and its applications to approximate reasoning. Parts I, II, III," *Information Science*, vol. 8-9, pp. 199–249, 301–357, 43–80, 1975.
- [22] J. H. Holland, "Adaptation in natural and artificial systems," *University of Michigan Press*, 1975.
- [23] A. E. Eiben and J. E. Smith, *Introduction to evolutionary computation*. Springer, 2003.
- [24] T. Bäck, D. Fogel, and Z. Michalewicz, *Handbook of evolutionary computation*. Oxford University Press, 1997.
- [25] M. J. del Jesus, P. González, F. Herrera, and M. Mesonero, "Evolutionary Fuzzy Rule Induction Process for Subgroup Discovery: A case study in marketing," *IEEE Transactions on Fuzzy Systems*, vol. 15, no. 4, pp. 578–592, 2007.
- [26] C. J. Carmona, P. González, M. J. del Jesus, and F. Herrera, "An Analysis of Evolutionary Algorithms with Different Types of Fuzzy Rules in Subgroup Discovery," in *Proceedings of the IEEE International Conference on Fuzzy Systems*, 2009, pp. 1706–1711.
- [27] M. J. del Jesus, P. González, and F. Herrera, *Fuzzy Sets and Their Extensions: Representation, Aggregation and Models*. Springer, 2007, vol. 220, ch. Subgroup Discovery with Linguistic Rules, pp. 411–430.
- [28] J. Alcalá-Fdez, L. Sánchez, S. García, M. del Jesus, S. Ventura, J. Garrell, J. Otero, C. Romero, J. Bacardit, V. Rivas, J. Fernández, and F. Herrera, "KEEL: A Software Tool to Assess Evolutionary Algorithms for Data Mining Problems," *Soft Computing*, vol. 13, no. 3, pp. 307–318, 2009.
- [29] J. Alcalá-Fdez, A. Fernández, J. Luengo, J. Derrac, S. García, L. Sánchez, and F. Herrera, "KEEL Data-Mining Software Tool: Data Set Repository, Integration of Algorithms and Experimental Analysis Framework," *Journal of Multiple-Valued Logic and Soft Computing*, vol. 17, no. 2-3, pp. 255–287, 2011.
- [30] F. J. Berlanga, M. J. del Jesus, P. González, F. Herrera, and M. Mesonero, "Multiobjective Evolutionary Induction of Subgroup Discovery Fuzzy Rules: A Case Study in Marketing," in *Proceedings of the 6th Industrial Conference on Data Mining*, ser. LNCS, vol. 4065. Springer, 2006, pp. 337–349.
- [31] M. J. del Jesus, P. González, and F. Herrera, "Multiobjective Genetic Algorithm for Extracting Subgroup Discovery Fuzzy Rules," in *Proceedings of the IEEE Symposium on Computational Intelligence in Multicriteria Decision Making*. IEEE Press, 2007, pp. 50–57.
- [32] E. Zitzler, M. Laumanns, and L. Thiele, "SPEA2: Improving the strength pareto evolutionary algorithm for multiobjective optimization," in *International Congress on Evolutionary Methods for Design Optimization and Control with Applications to Industrial Problems*, 2002, pp. 95–100.
- [33] K. Deb, *Multi-Objective Optimization using Evolutionary Algorithms*. John Wiley & Sons, 2001.
- [34] C. J. Carmona, P. González, M. J. del Jesus, and F. Herrera, "NMEEF-SD: Non-dominated Multi-objective Evolutionary algorithm for Extracting Fuzzy rules in Subgroup Discovery," *IEEE Transactions on Fuzzy Systems*, vol. 18, no. 5, pp. 958–970, 2010.
- [35] K. Deb, A. Pratap, S. Agrawal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.
- [36] C. J. Carmona, P. González, M. J. del Jesus, M. Navío, and L. Jiménez, "Evolutionary Fuzzy Rule Extraction for Subgroup Discovery in a Psychiatric Emergency Department," *Soft Computing Special Issue on "Genetic Fuzzy Systems"*, vol. In Press, 2011.
- [37] D. Gamberger and N. Lavrac, "Generating Actionable Knowledge by Expert-Guided Subgroup Discovery," in *Proceedings of the 6th European Conference on Principles and Practice of Knowledge Discovery in Databases*, ser. LNCS, vol. 2431. Springer, 2002, pp. 163–174.
- [38] C. J. Carmona, P. González, M. J. del Jesus, C. Romero, and S. Ventura, "Evolutionary algorithms for subgroup discovery applied to e-learning data," in *Proceedings of the IEEE International Education Engineering*, 2010, pp. 983–990.
- [39] C. Romero, P. González, S. Ventura, M. J. del Jesus, and F. Herrera, "Evolutionary algorithm for subgroup discovery in e-learning: A practical application using Moodle data," *Expert Systems with Applications*, vol. 36, pp. 1632–1644, 2009.
- [40] A. Bulbena, L. Sperry, C. Garcia-Ribera, A. Merino, G. Mateu, M. Torrens, J. San-Gil, and J. Cunillera, "Impact of the summer 2003 heat wave on the activity of two psychiatric emergency departments," in *Actas Esp. Psiquiatr.*, vol. 37, no. 3, 2009, pp. 158–165.
- [41] C. Romero and S. Ventura, "Educational data mining: a survey from 1995 to 2005," *Expert Systems with Applications*, vol. 33, no. 1, pp. 135–146, 2007.