



Eventos raros, anomalías y novedades vistas desde el paraguas de la clasificación supervisada

Ander Carreño
Intelligent Systems Group (ISG)
UPV/EHU
P. Manuel Lardizabal 1
20018 San Sebastián (Spain)
Email: ander.carreno@ehu.eus

Iñaki Inza
Intelligent Systems Group (ISG)
UPV/EHU
P. Manuel Lardizabal 1
20018 San Sebastián (Spain)
Email: inaki.inza@ehu.eus

Jose A. Lozano
Intelligent Systems Group (ISG)
UPV/EHU, 28018 San Sebastián (Spain)
Baque Center For Applied Mathematics
BCAM, 48009 Bilbao (Spain)
Email: ja.lozano@ehu.eus

Resumen—En los últimos años, muchas áreas han contribuido a resolver problemas denominados: eventos raros (*rare events*), anomalías (*anomalies*), novedades (*novelties*) y datos atípicos (*outliers*). Estas áreas han creado una mezcla entre términos y problemas. Por un lado, problemas similares han sido descritos con diferentes términos. Por el otro, el mismo término ha sido utilizado para describir problemas diferentes. Dada esta confusión, este artículo tiene como objetivo poner orden en el área viendo todos estos problemas desde el prisma de la clasificación supervisada. En concreto, se asocia a cada término un escenario de clasificación, se muestran ejemplos, y se consideran aquellas características asociadas a cada término que comparten la mayoría de artículos de la literatura. Por lo tanto, los escenarios se formalizan desde el punto de vista de la clasificación supervisada, se revisan los objetivos de la tarea de clasificación, las métricas usadas para evaluar el rendimiento, las características de los datos de entrada y las técnicas utilizadas en cada uno de ellos.

Index Terms—Eventos raros, anomalías, novedades, datos atípicos, outliers, aprendizaje automático, clasificación supervisada, aprendizaje desbalanceado.

I. INTRODUCCIÓN

Una gran cantidad de aplicaciones requieren filtrar o detectar observaciones anormales en los datos. En algunas situaciones, las anomalías son descritas como eventos raros, anomalías, novedades, outliers, excepciones, aberraciones, sorpresas, peculiaridades, ruido o contaminantes entre otras. De todas estas acepciones, las más comunes son: eventos raros, anomalías, novedades y outliers. La importancia de detectar estas anomalías es debido a que estas pueden estar relacionadas con situaciones críticas o interesantes en una gran cantidad de dominios. Por ejemplo, en seguridad, las intrusiones son consideradas anomalías [1]–[3]; en seguridad vial, los accidentes de tráfico son considerados anomalías [4]; en geología la erupción de un volcán es una anomalía [5]; en el control de alimentos, cuerpos extraños dentro de envoltorios son también anomalías [6]; o en el caso de la neurociencia, un estímulo que no se ha experimentado anteriormente es también una anomalía [7].

Considerando la importancia de las anomalías, se ha desarrollado una larga lista de trabajos relacionados con estos términos. Sin embargo, se ha formado una mezcla entre los términos y los problemas. En primer lugar, se han utilizado

diferentes términos para describir el mismo problema. Por ejemplo, en [8], los autores tratan un problema en el que predicen si se va a producir un desprendimiento en una zona concreta y en un periodo de tiempo acotado. Para ello, crean un mapa de zonas susceptibles a que ocurra un desprendimiento. Cada zona tiene asociado un riesgo de desprendimiento. Este riesgo se predice con un modelo aprendido con datos sobre zonas donde ha ocurrido un desprendimiento y zonas en las que no. Es decir, el modelo se aprende con datos etiquetados en dos categorías: desprendimiento y no desprendimiento. Estos desprendimientos de tierra son descritos como *eventos raros*, denotando que son eventos que ocurren pocas veces. No obstante, en [1], se trata un problema similar desde el punto de vista de la clasificación supervisada, pero que se describe con otro término. En éste, se realiza un estudio en la industria ferroviaria. Las puertas de pasajeros cuentan con diferentes sistemas para abrir y cerrar las puertas de los trenes, que aseguran el confort y la seguridad de los pasajeros abordo. En algunas situaciones, por el deterioro de estos sistemas, el sistema de apertura y cierre de las puertas falla. Por lo tanto, la tarea de predicción se enfoca en predecir si la puerta va a fallar en un periodo de tiempo acotado. Para ello, se aprende un modelo con datos etiquetados en dos categorías: fallos (puertas que fallan) y situaciones normales. En este estudio, los errores en las puertas se denominan *anomalías*, denotando también situaciones que ocurren pocas veces. Como se puede ver, los dos problemas son prácticamente idénticos desde el punto de vista de la clasificación supervisada, pero se han utilizado diferentes términos para describir las anomalías. Por lo tanto, analizando los problemas desde el punto de vista de la clasificación supervisada, ambos problemas se pueden modelar como problemas de clasificación binarios con distribuciones de probabilidad desbalanceadas en las clases.

Por otro lado, también el mismo término ha sido utilizado para describir problemas diferentes. En los siguientes dos problemas, los autores utilizan el término *novedad*, *novelty* en inglés, para describir las anomalías. En [3], detectan si un paciente está sufriendo un ataque epiléptico. Dada la fuerza de las convulsiones que sufren estos pacientes durante un ataque, pueden hacerse daño a ellos mismos. En consecuencia, detectar estos ataques lo más rápido posible es muy importante

para evitar los daños. Por lo tanto, el objetivo de este estudio es detectar si un paciente está sufriendo un ataque epiléptico. Para ello, se aprende un modelo predictivo con datos de movimientos de pacientes recogidos con un acelerómetro 3D. Estos datos previamente han sido grabados durante varios días en los cuales, en algún momento, los pacientes han sufrido una o varias convulsiones. Después, estos datos son segmentados en ventanas de tiempo fijas y, estas particiones son etiquetadas como ataque (porque ha sufrido un ataque en este tramo temporal) o como normal. Por lo tanto, cuando llega un nuevo caso, es decir, al recibir los datos de un paciente que está constantemente monitorizado, el clasificador detecta si está o no sufriendo un ataque epiléptico (i.e. identificado como novedad). Sin embargo en [6], se detectan cuerpos extraños dentro de contenedores de alimentos. En algunas ocasiones, ciertos cuerpos extraños como insectos, piedras o plásticos son encontrados dentro de los envoltorios de alimentos, tales como bandejas o tetrabriks. Detectar estos cuerpos extraños es muy importante para la imagen de las empresas productoras de este tipo de productos y para los consumidores finales. Por lo tanto, partiendo únicamente de imágenes de rayos X de alimentos limpios de cuerpos extraños, es decir, desde nuestro prisma, de una única clase, se aprende un modelo que es capaz de detectar estos cuerpos extraños, que son descritos como novedades en este estudio. Como se puede apreciar en ambos ejemplos, el mismo término (novedad) ha sido utilizado para describir las anomalías. No obstante, ambos trabajos no se basan en el mismo escenario de aprendizaje, y en [3] el modelo predictivo es aprendido con tanto instancias normales como anormales mientras que en [6] únicamente se aprende el modelo con datos normales (sin cuerpos extraños).

Sin embargo, no sólo los problemas descritos anteriormente, sino la mayoría de los problemas reseñados con los términos eventos raros, anomalías y novedades, se pueden formalizar como problemas de clasificación supervisada. Por lo tanto, este artículo trata de poner orden en esta mezcla y confusión de términos y problemas, asignando un único escenario de aprendizaje a cada uno de los términos, que viene a ser el más compartido en la literatura. Después, describe cada uno de los escenarios de clasificación mediante la asignación de aquellas características que más comparten los problemas de la literatura asociados a cada término.

El artículo se organiza de la siguiente manera. Cada sección corresponde a un escenario de clasificación, siendo: la Sección II para la detección de eventos raros, la Sección III para la detección de anomalías y la Sección IV para las novedades. En la Sección V se discute sobre el término outlier y, finalmente, en la Sección VI se exponen las conclusiones del artículo.

II. DETECCIÓN DE EVENTOS RAROS

La mayoría de los artículos que utilizan el término evento raro para describir las anomalías tienen la dimensión temporal como una característica clave. Por ejemplo en [4], se trata un problema relacionado con la seguridad vial en la autopista Attica (Grecia). Los autores dividen la autopista en diferentes secciones en las que quieren detectar si ha ocurrido

un accidente en la última hora. Para ello, crean un modelo basándose en información histórica tanto de sensores terrestres como de cámaras de tráfico en el que conocen si ha ocurrido un accidente en las diferentes secciones y en intervalos de 1 hora. Por lo tanto, llegada una nueva información de 1 hora en una sección, el clasificador predice la existencia de un accidente. Otra aplicación relacionada con el término evento raro, es [5]. En este artículo se realiza un estudio sobre la erupción de dos volcanes de Sudamérica. Los autores quieren detectar si estos volcanes van a entrar en erupción en una ventana de tiempo acotada. Para ello, aprenden un modelo con datos históricos de actividad volcánica en el que eventualmente hay erupciones. Esta estimación la realizan mediante un proceso de Poisson en el que se predice si va a haber o no una erupción en un horizonte acotado. Otro ejemplo diferente relacionado es [9]. En este artículo se realiza un estudio sobre la probabilidad de fallo en cascada de una red eléctrica. Para ello, los autores realizan un estudio por simulación numérica en el que someten a la red a diferentes situaciones climatológicas extremas de manera intencionada. Como puede observarse, la dimensión temporal de todos estos problemas es clave. Sin embargo, se observan dos objetivos diferentes en todos estos trabajos. Por un lado, la estimación de la probabilidad de ocurrencia de un evento raro. Por otro, la detección de eventos raros en una ventana de tiempo fija.

En el caso de la estimación de la probabilidad de ocurrencia de un evento raro, la probabilidad es estimada por simulación. Este tema se ha tratado especialmente en la física y la ingeniería. Ejemplos de aplicaciones de estimación de la probabilidad de un evento raro son: la estimación de fallo de una infraestructura [9], la probabilidad de fallo de sistemas técnicos [10], o la probabilidad de desarrollos climáticos extremos [11].

En la clasificación de eventos raros, las instancias son series temporales [12]. El objetivo es clasificar nuevas series temporales utilizando un modelo aprendido anteriormente. Sin embargo, dada la temporalidad de las instancias, existen dos aproximaciones de clasificación diferentes. En primer lugar, se encuentra la clasificación de eventos raros completos, es decir, de series temporales completas. Por ejemplo, en [13], se hace uso del conjunto de datos SMART¹ para predecir si el disco duro va a fallar en un periodo de tiempo acotado. Los datos consisten en una colección de medidas tomadas a lo largo del tiempo por sensores del disco duro cuando este está en uso. En [14], se hace uso de un conjunto de datos de tecnología térmica en el que se ha almacenado información sobre sistemas de calefacción. El objetivo es predecir si el sistema de calefacción está fallando o no. En segundo lugar, la clasificación temprana de eventos raros se ha tratado en la literatura [15] (*early classification*). El objetivo es clasificar las nuevas observaciones lo antes posible, preferiblemente, antes de que se complete la serie temporal. Esta temprana clasificación es crítica en una variedad de aplicaciones. Por ejemplo, en

¹El conjunto de datos SMART se compone de datos de uso de discos duros en los que se pueden ver errores como comportamiento normal.



[8] se realiza una predicción temprana de desprendimientos de tierra usando imágenes por satélite. O en [5], donde basándose en erupciones volcánicas del pasado, se predice si un volcán va a entrar en erupción o no en una ventana de tiempo fija.

De acuerdo a las distribuciones de probabilidad de los eventos raros (\mathcal{A}) y normales (\mathcal{N}), asumiendo que los datos son generados por el mecanismo generador $P(\mathbf{x}, c)$ [16], $P(C = \mathcal{A}) \ll P(C = \mathcal{N})$, los datos cuentan con una distribución desbalanceada de las clases. Por ello, la clasificación de eventos raros se puede formalizar bajo el marco de clasificación supervisada de series temporales con un (alto) desbalanceo de probabilidad sobre las clases [17], [18].

Sin embargo, en algunos problemas de clasificación de eventos raros, las instancias se transforman de tal forma que no se tiene en cuenta la información temporal en el proceso. Por esto, la clasificación de eventos raros se puede convertir en un problema de clasificación atemporal desbalanceado [4], [8].

Para evaluar el rendimiento de los clasificadores en la detección de eventos raros, métricas populares como el AUC [14], [19], [20] y el *recall* de la clase asociada al evento raro [14], [20] son utilizadas en la literatura.

II-A. Características de los datos de entrada

En la mayoría de los artículos referidos a la detección de eventos raros, los datos están etiquetados en dos categorías: normal (\mathcal{N}) y rara (\mathcal{A}). Las instancias son series temporales, una secuencia ordenada de pares (tiempo, valor) de longitud fija N ; $TS = \{(t_i, x_i), i = 1, \dots, N\}$ [12]. Tanto en el escenario de clasificación de eventos raros, como en el escenario de detección de anomalías, existe una distribución desbalanceada de las clases donde $P(C = \mathcal{A}) \ll P(C = \mathcal{N})$. En este escenario de clasificación, tanto las instancias normales como las anormales se encuentran en el conjunto de entrenamiento del modelo.

II-B. Técnicas

Entre las técnicas utilizadas en la literatura para estimar la probabilidad de ocurrencia de un evento raro se encuentran: *importance sampling*, simulaciones de Monte Carlo [21], [22], *kriging* [22] o *first order reliability methods (FORM)* [23]. De acuerdo con la clasificación de eventos raros, la técnica *rare event logistic regression*, una adaptación de la regresión logística, ha sido explícitamente propuesta en este escenario de clasificación [4], [8], [20], [24]. No obstante, técnicas populares de clasificación han sido aplicadas con éxito, como son la discriminación por divergencia de *Kullback-Leibler* [19], las redes neuronales de memoria a corto y largo plazo [14], los algoritmos genéticos [25], *naïve Bayes* para múltiples instancias [13], los procesos de Poisson [5], los *support vector data regression surrogates* [26], las redes Bayesianas [27], las máquinas de soporte vectorial [28] o el *AdaBoost* [29].

Por otro lado, teniendo en cuenta la distribución desbalanceada de las clases, se han encontrado técnicas en la literatura que tratan con este tipo de situaciones, como son *Structure Preserving Over Sampling (SPO)* [18] o una técnica de muestreo similar al SMOTE [17].

III. DETECCIÓN DE ANOMALÍAS

En el escenario de detección de anomalías, comúnmente los datos son atemporales y etiquetados. El objetivo es detectar anomalías basándose en un modelo aprendido con datos históricos. El conjunto de entrenamiento se compone de tanto instancias normales como anormales (anomalías). Nótese que se espera que las instancias anómalas nuevas (no vistas) sean parecidas a aquellas provistas en el conjunto de entrenamiento del modelo. Por lo tanto, este escenario puede formalizarse bajo el marco de la clasificación supervisada con un (alto) desbalanceo de las clases, asumiendo que los datos se generan por un mecanismo generador $P(\mathbf{x}, c)$ [16], $P(C = \mathcal{A}) \ll P(C = \mathcal{N})$. Esta distribución desbalanceada de los datos hace que los clasificadores estándar estén abrumados por la clase mayoritaria (anormal) e ignoren la minoritaria (normal) [30].

Para evaluar el rendimiento de los clasificadores en este escenario, dado el (alto) desbalanceo de las clases, métricas comunes como el *accuracy* no son lo suficiente representativas. Por ello, focalizándose en la correcta clasificación de las anomalías; o lo que es lo mismo, minimizando el error de tipo II, una métrica de evaluación popular utilizada en la literatura es el *recall* de la clase minoritaria [1], [31]. Sin embargo, otras métricas de evaluación pueden ser utilizadas como las que se revisan en [32].

III-A. Características de los datos de entrada

En la detección de anomalías, los datos son atemporales y, en la mayoría de las aplicaciones, están etiquetados en dos categorías: normal (\mathcal{N}) y anómalo (\mathcal{A}). En este escenario de clasificación existe una distribución desbalanceada de estas dos categorías, por lo que se tienen muchas más instancias de la clase normal que de la anormal. Sin embargo, en el conjunto de entrenamiento, se tienen tanto instancias de la clase normal como de la clase anómala.

III-B. Técnicas

Entre las técnicas específicas creadas bajo el entorno de detección de anomalías, se encuentra el popular *Isolation Forest* [33]. Por otro lado, se han adaptado técnicas de clasificación para resolver problemas en este ámbito, como son: las máquinas de soporte vectorial [34], los *random forests* [35], los clasificadores Bayesianos [36], las redes neuronales [37], o los modelos basados en mixturas de gaussianas [38]. Nótese que dado que la detección de anomalías se puede formalizar como un escenario de clasificación supervisada con distribuciones de probabilidad (altamente) desbalanceadas, es posible utilizar técnicas específicas para el desbalanceo, como puede ser el *Synthetic Minority Oversampling Technique (SMOTE)* [39], [40].

IV. DETECCIÓN DE NOVEDADES

En detección de novedades, comúnmente las instancias son atemporales y durante la etapa de entrenamiento, no se proporcionan instancias anormales [2], [6], [7]. El objetivo es clasificar si una nueva instancia pertenece al conjunto

normal provisto en entrenamiento o no, basándose en un modelo aprendido únicamente con instancias de una clase. Después, el modelo debe ser capaz de detectar cualquier grupo de instancias discordantes que es posible que formen una nueva clase [41]. Nótese que quizá sea necesaria la intervención de un experto para poder consolidar esta última anotación de una nueva clase. Por ejemplo, en este estudio de neurociencia [7], una novedad se considera un estímulo que no ha sido experimentado anteriormente. Este nuevo estímulo puede compartir características con otros nuevos estímulos no vistos en momento de entrenamiento, formando una clase o un nuevo tipo de estímulo. En el control alimenticio, los objetos extraños dentro de los envoltorios de los alimentos, como las piedras, los plásticos o insectos, son considerados novedades [6]. En este caso, es posible que las piedras de un alimento tengan características parecidas a otras observaciones no vistas en el conjunto de entrenamiento que contenga también una piedra.

En la detección de novedades, el conjunto de entrenamiento es generado únicamente por $P(\mathbf{X}|C = \mathcal{N})$. Consecuentemente, no se posee conocimiento alguno sobre las novedades cuando se aprende el primer modelo. Por lo tanto, en la creación del modelo, se debe asumir que las novedades estarán uniformemente distribuidas en el espacio de características. Esto es razonable dado que al no poseer ninguna información a priori, cualquier suposición es inconsistente. Sin embargo, una vez que se reconocen algunas novedades, estas pueden formar una clase nueva, por lo que el problema puede pasar a ser un problema de clasificación supervisada con distribuciones de probabilidad de clases desbalanceadas [41]. Para clarificar este último concepto, considérese un estudio médico en el que se proporcionan electrocardiogramas asociados a una enfermedad concreta como conjunto de entrenamiento. En la etapa de predicción, ciertos electrocardiogramas muestran una discordancia notable con aquellos de la etapa de entrenamiento. Por lo tanto, el clasificador los etiqueta como novedades. No obstante, se sabe que estos electrocardiogramas marcados como novedad, están relacionados con otra enfermedad. Por ello, es razonable pensar que estos electrocardiogramas comparten características entre ellos y que por tanto, crear una nueva clase para representar a los mismos sería una buena aproximación.

Por otro lado, también se ha tratado la detección de novedades en un entorno dinámico o *stream*. Por ejemplo en [41], partiendo de un conjunto de clasificación supervisada, los autores detectan nuevas clases combinando técnicas de clasificación supervisada y no supervisada. En concreto, si las instancias etiquetadas como novedades son suficientemente densas y distintas a las demás, estas son etiquetadas como una nueva clase.

Finalmente, para evaluar el rendimiento de estos clasificadores, es necesario señalar que la clasificación se centra principalmente en detectar las instancias normales proporcionadas en momento de entrenamiento [3], [33], [42]. Por lo tanto, las métricas de evaluación se basan en la minimización del error de tipo I. Una medida popular es la maximización del *recall* de la clase normal [3], [42].

IV-A. Características de los datos de entrada

En el escenario de detección de novedades, no se provee de instancias nóveles en el conjunto de entrenamiento. El modelo es aprendido únicamente con instancias de una clase. Se espera que en momento de predicción puedan llegar tanto instancias de una como de otra (novel) clase. Sin embargo, también se espera una distribución de probabilidad desbalanceada sobre las clases normal y novel $P(C = \mathcal{N}) \ll P(C \neq \mathcal{N})$ [7]. Además, se asume uniformidad sobre la distribución de las instancias novel.

IV-B. Técnicas

Las técnicas especialmente diseñadas para la detección de novedades tienen en cuenta que aprenden únicamente de una clase y son capaces de discernir si una nueva instancia forma parte o no de este comportamiento. Por lo tanto, las técnicas más representativas de este escenario de clasificación son aquellas relacionadas con el marco *one class*. Por ejemplo, *one class SVM* [28], [43], [44], *K-Nearest Neighbors data description* [45], *graph embeded one-class classifiers* [46] y *one-class random forests* [47] han sido propuestas en la literatura en escenarios de detección de novedades.

V. DISCUSIÓN: DETECCIÓN DE OUTLIERS

El término dato atípico, *outlier* en inglés tiene características comunes a los demás términos. Por ejemplo, las instancias pueden ser tanto temporales (series temporales) [48] como atemporales [49]–[51].

No obstante, aunque similar, el término outlier tiene diferencias clave con el resto de términos analizados. La diferencia más significativa es que los datos no están etiquetados, es decir, la tarea de predicción se realiza bajo el marco de la clasificación no supervisada [49]. Por lo tanto, en contraposición al resto de escenarios, no se asume que al menos existen dos clases en el problema de predicción. En ocasiones, el término outlier también se ha relacionado con el *ruido* sugiriendo que estas observaciones pueden ser inconsistentes o incorrectas [49]. Por ejemplo, cuando se cometen errores humanos al recoger los datos, estos comportamientos erráticos son considerados outliers [52]. En cambio, en otras situaciones, el término outlier se ha relacionado con instancias con alta varianza [51], [53]. Por ejemplo en [51], los autores detectan jugadores *all-star* de la NBA en un conjunto de datos constituido por jugadores de baloncesto entre los años 1973 y 2003. Los jugadores excepcionales son considerados outliers. Para detectarlos, los autores realizan un *clustering* y aquellos puntos que se desvían significativamente son considerados outliers.

Sin embargo, la detección de los outliers es subjetiva [49]. ¿Cuánto debe desviarse una observación del resto para considerarla como atípica? En la literatura existen múltiples criterios para responder a esta pregunta [51], [54], [55]. Para clarificarla, en la Figura 1 se describen dos situaciones para la detección de outliers. En 1a el punto marcado con *A* es considerado dato atípico dada la desviación significativa hacia uno y otro grupo. No obstante, cuando existe mucha más




Figura 1: Diferentes escenarios de outliers. Por [49].

Cuadro I: Resumen de las características de los diferentes escenarios de aprendizaje.

| | Eventos raros | Anomalías | Novedades | Outliers |
|---|---------------|-----------|-----------|----------|
| Siempre relacionado con dominios temporales | ✓ | ✗ | ✗ | ✗ |
| Distribución desbalanceada de las clases | ✓ | ✓ | ✓ | - |
| Observaciones anormales durante la etapa de entrenamiento | ✓ | ✓ | ✗ | - |
| Se realiza predicción sobre clases previamente vistas | ✓ | ✓ | ✗ | ✗ |
| Clasificación supervisada | ✓ | ✓ | ✓ | ✗ |

dispersión en los datos, este concepto puede ser más difuso y complejo. Este comportamiento se puede ver en 1b. En 1b, dados los demás outliers alrededor del punto A, la densidad del punto A es mayor y puede que quede difuminado el criterio de separación, haciendo una detección más difícil.

VI. CONCLUSIONES

Por un lado, los términos eventos raros, anomalías y novedades se han utilizado para describir problemas de clasificación similares en la literatura. Por el otro, problemas similares han sido descritos con diferentes términos. Además, estos términos se han utilizado indistintamente sin tener en cuenta las características que los diferencian. Por ello, en este artículo se han remarcado las características genuinas de cada uno de los términos. Para ello, se han extraído las características que más comparten los trabajos de la literatura referidos a cada término y se han revisado los objetivos, las características de los datos de entrada, y las técnicas utilizadas en los respectivos trabajos. Además, se ha argumentado que estos escenarios de aprendizaje pueden ser formalizados como problemas de clasificación supervisada con un (alto) desbalanceo entre las distribuciones de probabilidad de las clases. Consecuentemente, las técnicas específicas para tratar el desbalanceo pueden ser adaptadas y utilizadas en estos escenarios. En la Tabla I se muestra un resumen de las principales características de los diferentes escenarios de aprendizaje tratadas en este trabajo.

VII. AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Gobierno Vasco (IT609-13) y por el Ministerio de Economía, Industria y Competitividad (TIN2016-78365-R). Ander Carreño posee una beca del Ministerio de Economía, Industria y Competitividad (BES-2017-080016). J.A. Lozano posee financiación tanto del programa BERC 2018-2021 (Gobierno Vasco) como del programa Severo Ochoa SEV-2017-0718 (Ministerio de Economía, Industria y Competitividad).

REFERENCIAS

- [1] R. P. Ribeiro, P. Pereira, and J. Gama, "Sequential anomalies: a study in the Railway Industry," *Machine Learning*, vol. 105, no. 1, pp. 127–153, oct 2016.
- [2] M. A. F. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko, "A review of novelty detection," *Signal Processing*, vol. 99, pp. 215–249, 2014.
- [3] S. Luca, D. A. Clifton, and B. Vanrumste, "One-class classification of point patterns of extremes," *Journal of Machine Learning Research*, vol. 17, pp. 1–21, 2016.
- [4] A. Theofilatos, G. Yannis, P. Kopelias, and F. Papadimitriou, "Predicting Road Accidents: A Rare-events Modeling Approach," in *Transportation Research Procedia*, 2016.
- [5] Y. Dzierma and H. Wehrmann, "Eruption time series statistically examined: Probabilities of future eruptions at Villarrica and Llaima Volcanoes, Southern Volcanic Zone, Chile," *Journal of Volcanology and Geothermal Research*, 2010.
- [6] H. Einarsdóttir, M. J. Emerson, L. H. Clemmensen, K. Scherer, K. Willer, M. Bech, R. Larsen, B. K. Ersbøll, and F. Pfeiffer, "Novelty detection of foreign objects in food using multi-modal X-ray imaging," *Food Control*, vol. 67, pp. 39–47, sep 2016.
- [7] A. Kafkas and D. Montaldi, "How do memory systems detect and respond to novelty?" *Neuroscience Letters*, feb 2018.
- [8] M. Van Den Eeckhaut, T. Vanwalleggem, J. Poesen, G. Govers, G. Verstraeten, and L. Vandekerckhove, "Prediction of landslide susceptibility using rare events logistic regression: A case-study in the Flemish Ardennes (Belgium)," *Geomorphology*, vol. 76, no. 3-4, pp. 392–410, 2006.
- [9] L. Dueñas-Osorio and S. M. Vemuru, "Cascading failures in complex infrastructure systems," *Structural Safety*, vol. 31, no. 2, pp. 157–167, mar 2009.
- [10] T. Bedford and R. M. Cooke, *Probabilistic risk analysis: foundations and methods*. Cambridge University Press, 2001.
- [11] S. Dessai and M. Hulme, "Does climate adaptation policy need probabilities?" *Climate Policy*, vol. 4, no. 2, pp. 107–128, jan 2004.
- [12] P. Esling and C. Agon, "Time-series data mining," *ACM Computing Surveys*, vol. 45, no. 1, pp. 1–34, nov 2012.
- [13] J. F. Murray, G. F. Hughes, and K. Kreutz-Delgado, "Machine Learning Methods for Predicting Failures in Hard Drives: A Multiple-Instance Application," *J. Mach. Learn. Res.*, 2005.
- [14] S. Zhang, S. Bahrampour, N. Ramakrishnan, L. Schott, and M. Shah, "Deep learning on symbolic representations for large-scale heterogeneous time-series event prediction," in *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, mar 2017, pp. 5970–5974.
- [15] U. Mori, "Contributions to time series data mining departing from the problem of road travel time modeling," Ph.D. dissertation, University of the Basque Country, 2015.
- [16] T. M. T. M. Mitchell, *Machine Learning*. McGraw-Hill, 1997.
- [17] S. Köknar-Tezel and L. J. Latecki, "Improving SVM classification on imbalanced time series data sets with ghost points," *Knowledge and Information Systems*, vol. 28, no. 1, pp. 1–23, jul 2011.
- [18] H. Cao, X.-L. Li, Y.-K. Woon, and S.-K. Ng, "SPO: Structure Preserving Oversampling for Imbalanced Time Series Classification," in *2011 IEEE 11th International Conference on Data Mining*. IEEE, dec 2011, pp. 1008–1013.
- [19] J. Xu, S. Denman, C. Fookes, and S. Sridharan, "Detecting rare events using Kullback-Leibler divergence: A weakly supervised approach," *Expert Systems with Applications*, 2016.

- [20] Y. Ren, Y. Wang, X. Wu, G. Yu, and C. Ding, "Influential factors of red-light running at signalized intersection and prediction using a rare events logistic regression model," *Accident Analysis and Prevention*, 2016.
- [21] M. Balesdent, J. Morio, and L. Brevault, "Rare Event Probability Estimation in the Presence of Epistemic Uncertainty on Input Probability Distribution Parameters," *Methodology and Computing in Applied Probability*, 2016.
- [22] Y. Auffray, P. Barbillon, and J. M. Marin, "Bounding rare event probabilities in computer experiments," *Computational Statistics and Data Analysis*, 2014.
- [23] D. Straub, I. Papaioannou, and W. Betz, "Bayesian analysis of rare events," *Journal of Computational Physics*, 2016.
- [24] G. King, G. Langche Zeng, J. Fowler, E. Katz, M. Tomz for research assistance, J. Alt, J. Freeman, K. Gleditsch, G. Imbens, C. Manski, P. McCullagh, W. Mebane, J. Nagler, B. Russett, K. Scheve, P. Schrodt, M. Tanner, R. Tucker for helpful suggestions, S. Bennett, P. Huth, and R. Tucker, "Logistic Regression in Rare Events Data," *Political Analysis*, vol. 9, no. 2, pp. 137–163, 2001.
- [25] G. M. Weiss and H. Hirsh, "Learning to Predict Rare Events in Event Sequences," *Proceedings of the 4th International Conference on Knowledge Discovery and Data Mining*, 1998.
- [26] J.-M. Bourinet, "Rare-event probability estimation with adaptive support vector regression surrogates," *Reliability Engineering and System Safety*, 2016.
- [27] S.-P. Cheon, S. Kim, S.-Y. Lee, and C.-B. Lee, "Bayesian networks based rare event prediction with sensor data," *Knowledge-Based Systems*, 2009.
- [28] W. Khreich, B. Khosravifar, A. Hamou-Lhadji, and C. Talhi, "An anomaly detection system based on variable N-gram features and one-class SVM," *Information and Software Technology*, 2017.
- [29] J. Wu, J. M. Rehg, and M. D. Mullin, "Learning a Rare Event Detection Cascade by Direct Feature Selection," *Neural Information Processing Systems (NIPS)*, vol. 16, 2003.
- [30] N. V. Chawla, N. Japkowicz, and A. Ko, "Editorial: Special Issue on Learning from Imbalanced Data Sets," *Sigkdd Explorations*, vol. 6, no. 1, p. 1, 2004.
- [31] A. Ogbechie, J. Díaz-Rozo, P. Larrañaga, and C. Bielza, "Dynamic Bayesian Network-Based Anomaly Detection for In-Process Visual Inspection of Laser Surface Heat Treatment," *Machine Learning for Cyber Physical Systems*, pp. 17–24, 2017.
- [32] J. Ortigosa-Hernández, I. Inza, and J. A. Lozano, "Towards competitive classifiers for unbalanced classification problems: a study on the performance scores," 2016.
- [33] D. Zhang, N. Li, Z.-H. Zhou, C. Chen, L. Sun, and S. Li, "iBAT: Detecting anomalous taxi trajectories from GPS traces," *Proceedings of the 13th International Conference on Ubiquitous Computing (UbiComp '11)*, pp. 99–108, 2011.
- [34] Y. Zhou, W. Su, L. Ding, H. Luo, and P. Love, "Predicting Safety Risks in Deep Foundation Pits in Subway Infrastructure Projects: Support Vector Machine Approach," *Journal of Computing in Civil Engineering*, vol. 31, no. 5, p. 04017052, 2017.
- [35] S. Fan, G. Liu, and Z. Chen, "Anomaly detection methods for bankruptcy prediction," *2017 4th International Conference on Systems and Informatics (ICSAI)*, no. 17, pp. 1456–1460, 2017.
- [36] N. A. Heard, D. J. Weston, K. Platanioti, and D. J. Hand, "Bayesian anomaly detection methods for social networks," *Annals of Applied Statistics*, vol. 4, no. 2, pp. 645–662, 2010.
- [37] K. Noto, C. Brodley, and D. Slonim, "FRaC: a feature-modeling approach for semi-supervised and unsupervised anomaly detection," *Data mining and knowledge discovery*, vol. 25, no. 1, pp. 109–133, 2012.
- [38] D. Reynolds, "Gaussian Mixture Models," in *Encyclopedia of Biometrics*. Boston, MA: Springer US, 2015, pp. 827–832.
- [39] S. Miri Rostami and M. Ahmadzadeh, "Extracting Predictor Variables to Construct Breast Cancer Survivability Model with Class Imbalance Problem," *Shahrood University of Technology*, vol. 6, no. 2, pp. 263–276, jul 2018.
- [40] M. Araujo, R. Bhojwani, J. Srivastava, L. Kazaglis, and C. Iber, "ML Approach for Early Detection of Sleep Apnea Treatment Abandonment," *Proceedings of the 2018 International Conference on Digital Health - DH '18*, pp. 75–79, 2018.
- [41] M. M. Masud, Q. Chen, L. Khan, C. C. Aggarwal, J. Gao, J. Han, A. Srivastava, and N. C. Oza, "Classification and Adaptive Novel Class Detection of Feature-Evolving Data Streams," *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, no. 7, pp. 1484–1497, jul 2013.
- [42] M. Swarnkar and N. Hubballi, "OCPAD: One class Naive Bayes classifier for payload based anomaly detection," *Expert Systems with Applications*, 2016.
- [43] F. Dufrenois and J. C. Noyer, "One class proximal support vector machines," *Pattern Recognition*, vol. 52, pp. 96–112, 2016.
- [44] S. M. Erfani, S. Rajasegarar, S. Karunasekera, and C. Leckie, "High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning," *Pattern Recognition*, 2016.
- [45] D. M. J. Tax, "One-class classification," 2001.
- [46] V. Mygdalis, A. Iosifidis, A. Tefas, and I. Pitas, "Graph Embedded One-Class Classifiers for media data classification," *Pattern Recognition*, vol. 60, pp. 585–595, dec 2016.
- [47] C. Désir, S. Bernard, C. Petitjean, and L. Heutte, "One class random forests," *Pattern Recognition*, vol. 46, no. 12, pp. 3490–3506, dec 2013.
- [48] M. Gupta, J. Gao, and C. C. Aggarwal, "Outlier Detection for Temporal Data : A Survey," *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, no. 1, pp. 1–20, 2013.
- [49] C. C. Aggarwal, *Outlier Analysis*. Springer International Publishing, 2017.
- [50] L. Swersky, H. O. Marques, R. J. G. B. Campello, and A. Zimek, "On the Evaluation of Outlier Detection and One-Class Classification Methods," *IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, pp. 1–10, 2016.
- [51] M. Radovanović, A. Nanopoulos, and M. Ivanović, "Reverse Nearest Neighbors in Unsupervised Distance-Based Outlier Detection," *IEEE Transactions on Knowledge and Data Engineering*, vol. 4347, no. OCTOBER, pp. 1–14, 2014.
- [52] A. Barai and D. Lopamudra, "Outlier Detection and Removal Algorithm in K-Means and Hierarchical Clustering," *World Journal of Computer Application and Technology*, vol. 5, no. 2, pp. 24–29, 2017.
- [53] X. H. Dang, I. Assent, R. T. Ng, A. Zimek, E. Schubert, Xuan Hong Dang, I. Assent, R. T. Ng, A. Zimek, and E. Schubert, "Discriminative features for identifying and interpreting outliers," *Proceedings - International Conference on Data Engineering*, pp. 88–99, mar 2014.
- [54] M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, "A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise," *Kdd*, vol. 96, no. 34, pp. 226–231, 1996.
- [55] S. Ramaswamy, R. Rastogi, and K. Shim KAIST, "Efficient Algorithms for Mining Outliers from Large Data Sets," *ACM Sigmod Record* 2000, vol. 29, no. 2, pp. 427–438, 2016.