



Una aproximación desde la inteligencia computacional al tratamiento de datos de aseguradoras y accidentes

Ander Carreño

Start Date: 22 January 2018

Advisors: Iñaki Inza¹ and Jose A. Lozano^{1,2}

¹ Intelligent Systems Group, Universidad del País Vasco UPV/EHU
P. Manuel Lardizabal 1, 20018 San Sebastián (España)

² BCAM - Basque Center for Applied Mathematics
Avda. Mazarredo 14, 48009 Bilbao (España)
Emails: { ander.carreno, inaki.inza, ja.lozano }@ehu.eus

I. RESUMEN

En los últimos años, dentro del aprendizaje automático, ha surgido un gran interés por lo peculiar, raro, novedoso, sorprendente, anómalo, eventual, curioso, anormal o atípico. Tanto es así que áreas como la medicina [1], la geología [2], la banca [3], la seguridad informática [4] o la seguridad ferroviaria [5] han hecho avances en la detección de situaciones anómalas que se desvían notablemente del comportamiento habitual. Estas situaciones tienen la particularidad de que ocurren pocas veces, o lo que es lo mismo, que ocurren con baja probabilidad. Por lo tanto, detectarlas mediante técnicas predictivas es una tarea difícil. Pese a ello, numerosos trabajos han sido propuestos. La causa principal de la proliferación de estos artículos es que estos eventos están habitualmente asociados con causas críticas, como lo son los accidentes de tráfico [6] o las erupciones volcánicas [2]. Además, la detección de estos eventos supone un reto científico de especial interés dado que es necesario proponer avances metodológicos para dar solución a estos problemas.

Recientemente, el aprendizaje automático se ha incorporado al desarrollo de modelos para la predicción de eventos raros. Sin embargo, en contadas ocasiones se utiliza la terminología evento raros [7]. Este término es más común en otras áreas como la estadística, la ingeniería o la física. A pesar de ello, existen otro tipo de aproximaciones que tangencialmente tratan este problema de predicción; aunque poseen diferentes nombres:

- Clasificación supervisada en conjuntos extremadamente desequilibrados [8]. Se plantea un problema de clasificación donde una de las clases tiene una probabilidad de ocurrencia a priori extremadamente pequeña. No obstante, las instancias anómalas forman una clase, por lo que estas instancias comparten características entre sí. Por lo tanto, técnicas de muestreo como SMOTE [9] son un buen punto de partida para este escenario.

- *One-class classification* [10], [11]. En este caso el objetivo es crear un clasificador donde únicamente se trata de identificar casos de una sola clase, la clase de interés, es decir el evento raro. Muchos de los trabajos que utilizan la técnica de clasificación *one-class* se refieren a las anomalías como novedades. Al aprender un modelo sobre únicamente instancias de la clase conocida, la que es proporcionada en el momento de entrenamiento, cuando una nueva instancia, se clasifica como novel es porque es discordante con respecto al conjunto proporcionado.
- Detección de eventos raros [5]. En este escenario de clasificación, muchos de los trabajos que se han propuesto tienen la dimensión temporal como un elemento fundamental.
- Detección de outliers [12]. Al igual que en el caso anterior el objetivo es detectar datos en un conjunto que escapan a la situación más común. Sin embargo, muchos de los trabajos que describen las anomalías con el término outlier, toman una aproximación no supervisada.

Pese a que el problema de detección de eventos raros ha sido tratado en los últimos años, no se han realizado avances en la regresión sobre las características asociadas a un evento raro. Por ejemplo, es de gran interés predecir la escala Richter de un terremoto antes de que suceda. Dado que se podrían tomar medidas de evacuación y seguridad. Para llevar a cabo este análisis, no sólo es necesario detectar el terremoto, sino que también es necesario estimar la escala de éste. Otro ejemplo es la predicción del gasto por indemnizaciones asociado a un accidente de tráfico. Donde el problema deja de ser un problema de clasificación para convertirse en un problema de regresión.

Por lo tanto, este proyecto de tesis trata de aportar contribuciones metodológicas al ámbito de la regresión en eventos raros y su aplicación sobre datos reales de compañías de seguros. Para ello, se establecen los siguientes objetivos que

se alcanzarán durante el transcurso de la tesis doctoral:

- **Objetivo I.** Organizar el conocimiento dentro del ámbito del aprendizaje automático sobre la detección de eventos raros.
- **Objetivo II.** Desarrollar técnicas de regresión en el ámbito de eventos raros a partir de la detección inicial del evento raro mediante técnicas de clasificación.
- **Objetivo III.** Desarrollar técnicas de regresión en eventos raros de forma directa, es decir, sin predecir con anterioridad la existencia del evento raro mediante técnicas de clasificación.
- **Objetivo IV.** Aplicar las técnicas desarrolladas en los objetivos anteriores sobre datos reales provenientes de una compañía de seguros pública en la predicción de indemnizaciones.

Para la consecución de estos objetivos, la metodología a seguir contempla que una vez acabado uno de los objetivos, este será formalizado en un documento científico que será enviado para revisión y evaluación a una revista del ISI, pudiendo enviar algunos resultados parciales a congresos de prestigio dentro del área. En concreto, esta metodología desencadena las siguientes **tareas** para cada uno de los objetivos, siendo:

- **Objetivo I.** Organizar el conocimiento dentro del ámbito del aprendizaje automático sobre la detección de eventos raros.
 - Tarea 1.1. Búsqueda de bibliografía dentro del ámbito del aprendizaje automático que este relacionada con la detección de eventos raros. Además de buscar información relativa a los términos mencionados en el apartado de “antecedentes”, se tratará de buscar también la existencia de otros trabajos que con términos diferentes hayan abordado el problema de la detección de eventos raros.
 - Tarea 1.2. Organización de la información obtenida. Se identificarán aquellas características que agrupen tanto a problemas como algoritmos.
 - Tarea 1.3. Se redactará un artículo de investigación de revisión con la estructuración de la información anterior. Dicho artículo tendrá como uno de sus objetivos establecer una terminología común.
- **Objetivo II.** Implementar técnicas originales y novedosas de regresión en el ámbito de eventos raros a partir de la detección inicial del evento raro mediante técnicas de clasificación.
 - Tarea 2.1. Implementación de varias técnicas de clasificación supervisada para la detección de eventos. Partiendo de la revisión llevada a cabo en el anterior objetivo, se implementarán aquellas técnicas que parezcan más adecuadas para el posterior trabajo de regresión.
 - Tarea 2.2. Implementación de varias técnicas de regresión que tengan en cuenta que los posibles valores de salida de la regresión asociados al evento raro pueden tener gran variabilidad. La elección de las técnicas se llevará cabo tras un estudio bibliográfico

exhaustivo.

- Tarea 2.3. Creación de varios modelos de predicción híbridos basados en la detección del evento raro mediante técnicas de clasificación para a posteriori realizar la regresión asociada a dicho evento. Uniendo técnicas clásicas de estadística con algoritmos de aprendizaje automático.
- Tarea 2.4. Preparación de un documento científico con lo realizado para la consecución del objetivo.
- **Objetivo III.** Implementar técnicas novedosas de regresión en eventos raros de forma directa, es decir, sin predecir con anterioridad la existencia del evento raro mediante técnicas de clasificación.
 - Tarea 3.1. Estudiar en la literatura técnicas de regresión que consideren la existencia de eventos raros.
 - Tarea 3.2. Desarrollar técnicas capaces de predecir el valor de interés asociado a un evento raro. En el desarrollo de estas técnicas se considerará de especial manera la hibridación entre técnicas estadísticas clásicas con métodos de aprendizaje automático.
 - Tarea 3.3. Implementación y evaluación de las diferentes técnicas desarrolladas. Se creará un software que se pondrá a disposición de la comunidad científica. Este software, que recogerá las técnicas desarrolladas, se implementará en el lenguaje R y se subirá al repositorio CRAN. Dependiendo del número y novedad de las técnicas desarrolladas se escribirá un artículo donde se detallarán las características del paquete desarrollado, el cual será enviado a revistas como *The R journal* o *Journal of Statistical Software*.
 - Tarea 3.4. Preparación de un documento científico con lo realizado para la consecución del objetivo. Este trabajo, además de incluir los avances metodológicos, contendrá una experimentación detallada donde se utilizarán los datos de una compañía de seguros. En concreto, se hará regresión sobre las características asociadas a un accidente. Este documento contendrá todos los avances de la investigación y será publicado en una revista de alto impacto en la comunidad.
- **Objetivo IV.** Aplicar las técnicas desarrolladas en los objetivos anteriores sobre datos reales provenientes de una compañía de seguros pública en la predicción de indemnizaciones.
 - Tarea 4.1. Preproceso de los datos. El objetivo de esta tarea es realizar el preproceso de los datos que recibiremos de la compañía de seguros. Particularmente, se tratarán los datos perdidos, los registros incoherentes, y se llevará a cabo una selección de características.
 - Tarea 4.2. Aplicación de los métodos desarrollados en los objetivos anteriores a la predicción de las indemnizaciones. Este proceso será un proceso iterativo y se contará con apoyo de la compañía de



seguros aportando “feedback” sobre los resultados obtenidos.

- Tarea 4.3. Preparación de un documento científico con lo realizado para la consecución del objetivo. En este documento se incorporará una experimentación detallada donde se hará regresión sobre las características asociadas a un accidente de trabajo. Además, se compararán los resultados tanto con los de los trabajos anteriormente presentados como con las contribuciones relevantes en el área. Por último, los resultados parciales de este trabajo serán enviados a un congreso internacional de prestigio, como por ejemplo a *Conference on Artificial Intelligence (AAAI)* o a *Conference on Neural Information Processing Systems (NIPS)*.

II. ESTADO DEL ARTE

La detección de eventos raros se caracteriza por la baja probabilidad con la que suceden este tipo de eventos. De forma similar, los problemas de clasificación con distribuciones de probabilidad desbalanceadas están relacionados con la detección de eventos raros. No obstante, en la literatura proliferan una serie de términos que están relacionados entre sí pero que tienen diferencias clave. 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 [4], [5], [13]; en seguridad vial, los accidentes de tráfico son considerados anomalías [6]; en geología, la erupción de un volcán [2]; en el control de alimentos, cuerpos extraños dentro de envoltorios son también anomalías [14]; o en el caso de la neurociencia, un estímulo que no se ha experimentado anteriormente es también una anomalía [1].

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 [15], 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 [5], 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 análisis 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 escenarios de aprendizaje, los autores utilizan el término *novedad*, *novelty* en inglés, para describir las anomalías. En [13], los autores predicen 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 o normal por el experto. 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 [14], 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, 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 [13] el modelo

predictivo es aprendido con tanto instancias normales como anormales mientras que en [14] 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.

III. RELEVANCIA

Como se puede ver, en los últimos años ha habido una proliferación de trabajos en los que se detecta lo atípico o anormal. Sin embargo, al revisar la mayoría de estos trabajos, se puede ver que distan unos de otros teniendo en cuenta el objetivo del problema, la influencia de la dimensión temporal, las características de los datos, el entorno estático o dinámico, y la cantidad de clases en momento de entrenamiento. Por lo tanto, una taxonomía de este tipo de problemas es una contribución relevante en el área para organizar el conocimiento, no sólo en el área del aprendizaje automático sino en muchas otras con una rica trayectoria en aplicaciones de análisis de datos, como la medicina, las telecomunicaciones o la geología.

Por otro lado, la regresión de las características asociadas a una anomalía es muy relevante. Como se ha comentado, existen numerosos problemas reales en los cuales obtener un valor continuo asociado a una anomalía es de gran interés.

Por último, contribuir con un paquete que recogerá todas las técnicas y avances metodológicos para la regresión de anomalías es un avance y servicio para la comunidad. Además, dado que este paquete estará disponible en el lenguaje de programación R, será de software libre.

REFERENCIAS

- [1] A. Kafkas and D. Montaldi, "How do memory systems detect and respond to novelty?" *Neuroscience Letters*, 2 2018.
- [2] 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*, vol. 193, no. 1-2, pp. 82–92, 2010.
- [3] C. Phua, V. Lee, K. Smith, and R. Gayler, "A Comprehensive Survey of Data Mining-based Fraud Detection Research," *Monash University*, 2010.
- [4] 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.
- [5] 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, 10 2016.
- [6] A. Theofilatos, G. Yannis, P. Kopelias, and F. Papadimitriou, "Predicting Road Accidents: A Rare-events Modeling Approach," *Transportation Research Procedia*, vol. 14, pp. 3399–3405, 2016.
- [7] J. F. Murray, G. F. Hughes, and K. Kreutz-Delgado, "Machine Learning Methods for Predicting Failures in Hard Drives: A Multiple-Instance Application," *Journal of Machine Learning Research*, vol. 6, pp. 783–816, 2005.
- [8] 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.
- [9] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002. [Online]. Available: <https://www.jair.org/media/953/live-953-2037-jair.pdf>
- [10] 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*, vol. 58, pp. 121–134, 2016.
- [11] F. Dufrenois and J. C. Noyer, "One class proximal support vector machines," *Pattern Recognition*, vol. 52, pp. 96–112, 2016. [Online]. Available: <http://dx.doi.org/10.1016/j.patcog.2015.09.036>
- [12] M. Radovanović, A. Nanopoulos, and M. Ivanović, "Reverse nearest neighbors in unsupervised distance-based outlier detection," *IEEE Transactions on Knowledge and Data Engineering*, 2015.
- [13] 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.
- [14] 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, 9 2016.
- [15] M. Van Den Eeckhaut, T. Vanwalleghem, 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*, 2006.