

REDUCIENDO EL GAP ENTRE PERSONAS Y MACHINE LEARNING: LA ÉTICA DE LOS ALGORITMOS APLICADOS AL FRACASO EMPRESARIAL

Mariano Romero Martinez

José Pozuelo Campillo

Pedro Carmona Ibáñez

Departament de Comptabilitat

Universitat de València

Área temática: Información Financiera y Normalización Contable

CORRESPONDENCIA:

Mariano Romero Martinez

Departament de Comptabilitat – Universitat de València

Facultat d'Economia

Avg. dels Tarongers, s/n

46022 Valencia

**(*) Proyecto PGC2018-093645-B-I00 financiado por MCIN/AEI/10.13039/501100011033/ y por FEDER
Una manera de hacer Europa**

REDUCIENDO EL GAP ENTRE PERSONAS Y MACHINE LEARNING: LA ÉTICA DE LOS ALGORITMOS APLICADOS AL FRACASO EMPRESARIAL

RESUMEN

Ajustamos con el *XGBoosting* un modelo de aprendizaje automático muy preciso y desvelamos la objetividad ética de la caja negra del algoritmo, mejorando su interpretabilidad. Identificamos indicadores significativos de propensión al fracaso empresarial. Obtuvimos de la base de datos ORBIS información de una muestra de 3.806 empresas españolas (1.806 propensas al fracaso y 1.800 no propensas) en 2019, considerando el indicador de fortaleza financiera VADIS. Esta identificación de variables resulta crucial para la oportuna reacción de los usuarios. Los resultados revelan que mayores niveles de solvencia y rentabilidad y menor endeudamiento se asocian con una menor propensión al fracaso empresarial.

PALABRAS CLAVE: Fracaso empresarial, modelos de predicción, Machine Learning, XGBoost, ratios financieras, ética de los algoritmos.

REDUCIENDO EL GAP ENTRE PERSONAS Y MACHINE LEARNING: LA ÉTICA DE LOS ALGORITMOS APLICADOS AL FRACASO EMPRESARIAL

1.- INTRODUCCIÓN

Generalmente las crisis económicas suponen un considerable aumento de la tasa de fracaso empresarial y normalmente se ve acompañado del repunte del interés de investigadores por sus causas, consecuencias y detección. Para armar el sistema metodológico los estudios en este campo tradicionalmente han recurrido a técnicas estadísticas, hoy consideradas clásicas, de gran aceptación en su día como el análisis discriminante o la regresión logística (LR), basadas en lo que se ha denominado la cultura de los datos. En los últimos tiempos el catálogo de técnicas aplicadas a este campo ha aumentado considerablemente, incorporando aquellas basadas en la inteligencia artificial y el aprendizaje automático. Con su aplicación se ha conseguido entender mejor los procesos analizados y, en la mayoría de los casos, superar la capacidad predictiva y facilidad de aplicación de los modelos considerados clásicos.

En líneas generales el proceso el aprendizaje automático (AA) y el *Machine Learning (ML)* incorporan a su análisis algoritmos que absorben la información de un gran volumen de datos, tanto estructurados como no estructurados que inundan los negocios cada día para obtener información y predecir fenómenos complejos (Oyewo et al., 2020; Rapanyane y Sethole, 2020). Al incluir técnicas de naturaleza dinámica que se pueden ejecutar constantemente en segundo plano aportan a los gestores de la empresa información relevante en tiempo real que facilitan el proceso de toma de decisiones (Syam y Sharma, 2018). Destacan los estudios de Xia et al. (2017) quienes proponen un modelo de calificación crediticia que supera en confiabilidad y precisión los sistemas de calificación crediticia anteriores. Santhanam et al. (2017), por su parte, en estudio sobre empresas de servicio concluyen que la aplicación del algoritmo *Extreme Gradient Boosting (XGBoost)* proporciona el modelo más adecuado para analizar los aspectos que influyen en la retención de los clientes. Además, según Climent et al. (2019) este tipo de técnica funciona mejor que la regresión logística y otras técnicas estadísticas en cuestiones relacionadas con la insolvencia empresarial.

Una de las aplicaciones más innovadoras del aprendizaje automático es el mencionado *XGBoost*, algoritmo de aprendizaje supervisado que intenta predecir con la máxima precisión una variable objetivo al combinar las estimaciones de un conjunto de modelos más simples y débiles. El hecho de que este algoritmo confiera a los modelos una muy alta precisión y rapidez ha atraído el interés de investigadores de numerosos campos por incorporarlo a sus estudios. De hecho, su aplicación como técnica de predicción se viene utilizando con éxito

desde hace varios años en áreas de investigación como medicina, para el diagnóstico de patologías diversas (Merlet et al., 2001, Dettling y Bühlmann, 2003; Rodríguez Jiménez, 2005, Sanz et al., 2015), Sin embargo, su aplicación en economía es muy reciente, y concretamente en la previsión del fracaso empresarial la literatura cuenta con muy pocas aportaciones.

En el campo específico de la investigación del fracaso empresarial los estudios que se sirven de *XGBoost* son todavía más escasos. Climent et al. (2019) utilizan el algoritmo para identificar los indicadores financieros que podrían vaticinar la quiebra en las entidades financieras de la zona euro. Otro estudio, de naturaleza metodológica similar, pero aplicado a entidades financieras estadounidenses, es el realizado por Carmona et al (2019) quienes proponen una batería de indicadores idóneos para predecir las quiebras en ese tipo de empresas. En estos trabajos se puede destacar la superioridad de estas técnicas respecto a las clásicas a la hora de predecir y explicar situaciones de dificultad financiera en las empresas analizadas.

Recientemente ha visto la luz un trabajo de Carmona et al. (2022) en el que de manera novedosa se plantea descubrir el contenido de la caja negra asociada al *XGBoost* y muestra como utilizando esta técnica es posible ajustar un modelo de aprendizaje automático muy preciso y de fácil interpretación. Al tiempo logran identificar que los valores altos de indicadores como capital por empleado, solvencia, rentabilidad neta y un retorno sostenible de la inversión se asocian con un menor riesgo de fracaso empresarial contribuyendo, por tanto, predecir las potenciales dificultades financieras de las empresas. Este trabajo, además de enriquecer la literatura en el estudio del fracaso empresarial mediante esta técnica (*XGBOOST*), abre el camino a la introducción del debate ético en esta línea de investigación.

De hecho, el notable incremento del uso de algoritmos nos plantea las implicaciones éticas de una sociedad cada vez más gobernada por algoritmos. Cuando una persona, por ejemplo, pretende contratar un viaje, un software de inteligencia artificial realiza una valoración de ofertas atendiendo a la situación del consumidor, cuando se pretende contratar un seguro un algoritmo compara los precios, cuando una gran superficie te recomienda un determinado producto realmente quien lo hace es un algoritmo y cuando una empresa desea contratar un préstamo un software de inteligencia artificial realiza un estudio de sus posibilidades y ofrece determinadas alternativas en función de su aval financiero. Por ello, es muy importante comprender y saber quién gestiona la información, aspecto clave para las libertades individuales y colectivas. Según Monasterio (2017) “las implicaciones éticas de una sociedad cada vez más gobernada por algoritmos obligan a la industria, academia e instituciones públicas a buscar alianzas para crear una gobernanza transparente ética y justa de la caja de pandora que puede ser la inteligencia artificial”. A pesar de que la automatización de este tipo

puede generar numerosas interrupciones en la economía, es notorio que la inteligencia artificial aplicada de una forma neutral puede contribuir a mejorar numerosos campos de la cotidianidad de las personas.

Precisamente en este trabajo pretendemos desvelar el contenido de la caja negra mostrando los ratios que mejor alertan de futuras situaciones de dificultad financiera lo que la convertirán en una valiosa herramienta para los gestores de la empresa y demostrar que los resultados de la aplicación de esta técnica están desprovistos de subjetividades provistas de juicios previos sobre determinadas situaciones. Con ello añadimos bibliografía a un campo todavía inexplorado, pues en la exhaustiva revisión de la literatura llevada a cabo no hemos encontrado ningún trabajo específico que cuestione el contenido ético de la caja negra. Tan solo hemos podido comprobar que autores como Carmona et al. (2022) y Climent et al. (2019) incorporan a sus estudios estas técnicas, pero desde ópticas diferentes limitándose a identificar las ratios y su interpretabilidad. En nuestro trabajo pretendemos desvelar la objetividad ética del contenido de la caja negra con lo que paralelamente mejorará la interpretabilidad de los modelos propuestos.

El presente trabajo se ha estructurado de la manera siguiente. Tras una breve introducción realizamos una cuidadosa revisión de la literatura. A continuación, abordamos la parte metodológica y empírica estableciendo la definición de fracaso empresarial y las variables explicativas utilizadas en el estudio. Posteriormente, confeccionaremos una base de datos integrada por empresas cuyos registros cumplan las especificaciones exigidas por los objetivos del trabajo, a las que aplicaremos las técnicas de análisis y herramientas estadísticas. Por último, expondremos las conclusiones más relevantes derivadas del estudio realizado.

2.- REVISIÓN DE LA LITERATURA

Los estudios sobre el fracaso empresarial mediante modelos de predicción se remontan a la década de los sesenta del siglo pasado comenzando por el uso de técnicas univariantes (Beaver 1966). Con la búsqueda de mejoras metodológicas para superar ciertas deficiencias y limitaciones de los modelos pioneros se incorporaron sucesivamente técnicas multivariantes (Altman 1968), de probabilidad condicional (Ohlson 1980 y Zmijewski 1984), de particiones iterativas y finalmente, esta línea de investigación se ha visto fortalecida por la inteligencia artificial, (Frydman et al. 1985, Wilson y Sharda 1994). Esta evolución se ha visto acompañada de una incuestionable y paulatina mejora en capacidad, fiabilidad, interpretabilidad y facilidad

de aplicación de los diferentes modelos desarrollados. Sobre todas ellas existe una amplia bibliografía en la literatura contable nacional e internacional (Tascón y Castaño, 2012).

Desde hace relativamente poco tiempo estamos asistiendo a la irrupción en esta línea de investigación de numerosas propuestas basadas en la inteligencia artificial. El objetivo, aparte de mejorar y ampliar las herramientas de detección actuales, también se centra en superar ciertas restricciones propias de los modelos estadísticos tradicionales como la linealidad, la normalidad y sobre todo la estacionariedad derivada de la utilización de ratios financieros deducidos de la información financiera para unos determinados periodos. La evidencia empírica nos indica que en los procesos de fracaso empresarial influyen muchas más variables y factores determinantes. Las propuestas más significativas de estos nuevos métodos basados en la inteligencia artificial las encontramos en los recientes trabajos de (Mompalmer et al., 2020) quienes utilizan el análisis comparativo cualitativo de conjuntos borrosos (*fuzzy-set qualitative comparative analysis fsQCA*) para identificar las combinaciones de factores que conducen a la quiebra bancaria. Hosaka (2019) aplica una red neuronal convolucional a la predicción de la quiebra empresarial a una muestra de empresas japonesas. (Le y Viviani, 2018), por su parte, comparan la precisión de las técnicas estadísticas tradicionales (análisis discriminante y regresión logística) frente a las técnicas de aprendizaje automático (red neuronal artificial, *Support Vector Machines* y *k-nearest neighbors*) para detectar la quiebra empresarial en entidades financieras de EE. UU. Concluyen demostrando la superioridad y precisión de los métodos de red neuronal artificial y *k-nearest neighbors* para predecir la quiebra bancaria. (Pozuelo et al. 2018) utilizan la metodología basada en los algoritmos "*Gradient Boosting Machine*" (*GBM*) en la predicción de la quiebra de empresas españolas confirmando el alto poder predictivo de los modelos basados en esta metodología. También Lee y Choi (2013), aplicando la metodología de las redes neuronales de retropropagación (*propagation neural network BPN*) a un estudio sobre la quiebra en empresas coreanas, demuestran la superioridad previsional de *BPN* frente al análisis multivariante.

Tsai y Cheng (2012) analizan el poder de predicción de cuatro técnicas de clasificación populares. Comparan redes neuronales artificiales, árboles de decisión, regresión logística y máquinas de vectores de soporte (*support vector machines SVM*) en presencia de valores atípicos aplicadas a un conjunto de datos de competencia australiana, alemana y japonesa. Concluyen que son las máquinas de vectores de soporte (*SVM*) las que proporcionan la mayor tasa de precisión de predicción y funcionan con mucha más estabilidad y buena tolerancia al ruido que los otros tres modelos de predicción.

Erdogan (2013) propone un novedoso estudio aplicando máquinas de vectores de soporte (*SVM*) al análisis de quiebras bancarias a una muestra de bancos turcos. Este estudio muestra que las *SVM* con el núcleo gaussiano son capaces de extraer información útil de los datos financieros y se pueden utilizar como parte de un sistema de alerta temprana. Eling y Jia (2018), a partir de una muestra de empresas aseguradoras europeas fracasadas entre 2006 y 2013. Aplican el análisis envolvente de datos de última generación, la regresión logística y los enfoques de máquinas vectoriales de soporte observando que la eficiencia técnica y la volatilidad del negocio se correlacionan positivamente con la probabilidad de fracaso. Por ello, concluyen que *SVM* es mejor que la regresión logística.

Zhou et al. (2017) proponen un método mejorado de selección de características efectivas para predecir los estados de cotización de las empresas que cotizan en China. Se emplean modelos basados en árboles de decisión C4.5 y C5.0 y se comparan con otros modelos ampliamente utilizados, demostrando la eficacia del método de selección de características propuesto y del modelo C5.0 del árbol de decisión.

Zięba et al (2016) desarrollan un modelo predictivo combinando diversas medidas econométricas utilizando *XGBoost*. Se demuestra la superioridad predictiva frente a los métodos tradicionales. En la misma línea Jones (2017) concluye que el método de aprendizaje estadístico de *XGBoost* supera la limitación el análisis discriminante múltiple y logit. También Momparler et al. (2016) aplican la técnica *GBM* el estudio de la quiebra en entidades bancarias de la eurozona, en el que se obtienen unos resultados muy satisfactorios en cuanto al alto poder de predicción del modelo (un 98,67% de acierto). Carmona et al (2019) compararon la capacidad de *XGBoost*, *Random Forest* y LR para predecir la quiebra bancaria. Indican que *XGBoost* superó a otros modelos en términos de precisión y rendimiento de generalización. Jabeur et al (2021) proponen un enfoque novedoso para clasificar datos categóricos utilizando árboles de decisión de aumento de gradiente concretamente *CatBoost*, comparándolo con ocho modelos de aprendizaje automático de referencia observando una mejora efectiva en el poder del rendimiento de clasificación en comparación con otros enfoques avanzados.

Podemos concluir que en prácticamente todos los modelos basados en la inteligencia artificial identifican mejor los procesos de dificultad financiera que los modelos considerados tradicionales. En este estudio además de contribuir a ampliar la literatura en este campo, pretendemos desvelar el contenido de la caja negra de esta metodología y analizar su grado de objetividad en la información aportada. Pensamos que la autonomía de estos sistemas no puede servir de pretexto para la disolución de responsabilidades. Por ello, es preciso incluir

los mecanismos adecuados que doten de un alto grado de objetividad cualquier decisión adoptada.

3. OBJETIVO, MUESTRA Y VARIABLES EXPLICATIVAS

3.1. Objetivo del trabajo

El objetivo de este trabajo es desarrollar un modelo de clasificación entre empresas propensas al fracaso y no propensas al fracaso, utilizando técnicas del aprendizaje automático, en particular mediante el uso del algoritmo *XGBoost*, sobre datos financieros de empresas obtenidos de la base de datos ORBIS.

Para ello, hemos seleccionado y obtenido información financiera de empresas activas españolas del ejercicio 2019, antes de que influyera la situación pandémica en la situación financiera de las empresas. Dicha información financiera incluye datos de las cuentas anuales de las empresas, ratios y magnitudes financieros e indicadores de fortaleza financiera.

3.2 Indicadores de fortaleza. Indicador de propensión al fracaso VADIS.

La base de datos ORBIS ofrece una serie de indicadores de fortaleza financiera de gran utilidad para analizar diferentes aspectos sobre la viabilidad de las empresas.

En este trabajo hemos seleccionado el indicador de fortaleza VADIS que mide la evolución de las empresas considerando una gran cantidad de factores (unos 15.000 por empresa). Ofrece información sobre los siguientes aspectos:

- a) Propensión de una empresa a la quiebra (P2BB): Mide la probabilidad de que una empresa se declare en bancarrota en los próximos 18 meses.
- b) Propensión de una empresa a ser vendida (P2BSold). Mide la probabilidad de que una empresa venda en los próximos 18 meses.
- c) Valor estimado de la operación de la compañía (VPI EDV). Estima el valor de la operación futura de las empresas asociadas con un indicador P2BSold y se expresa en términos de un intervalo de confianza (es decir, tiene un límite superior e inferior).

El indicador VADIS, asociado a la propensión al fracaso, clasifica a las empresas en diferentes grados que van desde el 1 (menor propensión a quebrar) hasta 9 (mayor propensión a quebrar). La escala utilizada por este indicador se muestra en la tabla 1.

Tabla 1. Escala del indicador de fortaleza financiera VADIS s/propensión a la quiebra

	ESCALA DEL INDICADOR DE FORTALEZA FINANCIERA VADIS P2BB S/PROPENSIÓN A LA QUIEBRA:
Valor	El riesgo de quiebra de la empresa en los próximos 18 meses es
9	superior a 10 veces el promedio de su país
8	entre 5 y 10 veces el promedio de su país
7	entre 3 y 5 veces el promedio de su país
6	entre 2 y 3 veces el promedio de su país
5	entre 1 y 2 veces el promedio de su país
4	entre 1/2 y 1 del promedio de su país
3	entre 1/5 y 1/2 del promedio de su país
2	entre 1/10 y 1/5 del promedio de su país
1	inferior a 1/10 del promedio de su país

Fuente: Elaboración propia a partir de la información de la base de datos ORBIS (2021).

Las puntuaciones de este indicador se actualizan mensualmente siempre que se traten de empresas con datos financieros disponibles, recientes y detallados en la propia base de datos ORBIS, cuya calidad y cobertura es esencial para el modelo.

No obstante, la clasificación ofrecida por el indicador no resulta transparente para el usuario, ya que se desconoce con detalle los cálculos y motivos que la han originado. Por ello pretendemos en este trabajo dilucidar qué factores caracterizan a las empresas que son clasificadas por este indicador VADIS como propensas al fracaso empresarial frente a las que no lo son, a través del uso del mencionado algoritmo de inteligencia artificial *XBoost*.

3.3 Selección de la muestra

Hemos obtenido información financiera de la base de datos ORBIS de empresas activas españolas del ejercicio 2019 de todos los sectores de actividad salvo los de ámbito financiero.

De esta manera se han obtenido datos y ratios financieros de 42.247 empresas, además de información sobre el indicador de fortaleza financiera VADIS. A partir de él hemos identificado dos grupos de empresas, uno con una propensión no alta al fracaso y otro con una propensión muy alta al fracaso.

Para ello, hemos considerado como empresas altamente propensas al fracaso aquellas que poseen un alto valor del indicador de fortaleza financiera VADIS (grados 9 y 8) y como no altamente propensas al fracaso las que poseen un bajo valor en dicho indicador (grados 1 a 5), dejando de lado, para que no interfiriesen, las que obtienen un valor intermedio en dicho indicador (grados 6 y 7).

Con este criterio hemos identificado un total de 1.809 empresas con una propensión alta al fracaso y aleatoriamente hemos seleccionado 1.800 empresas con una propensión no alta al fracaso, tal como se detalla en la tabla 2. La muestra de empresas resulta equilibrada en la proporción de ambos grupos, un aspecto importante para la correcta aplicación de los algoritmos.

Tabla 2. Selección de la muestra

Clasificación VADIS	1	2	3	4	5	6	7	8	9
Empresas	2.159	6.047	13.926	5.528	6.348	2.611	1.867	1.334	475
Selección	34.008→aleatoriamente→1.800					0	0	1.809	
Propensión al fracaso	No alta							Alta	

Fuente: Elaboración propia a partir de los datos obtenidos de la base de datos ORBIS (2021).

Como último paso, para contrastar la capacidad predictiva o clasificatoria del modelo y su grado de generalización, se ha reservado un 20% de las observaciones (714 empresas) como muestra independiente de comprobación, para contrastar los resultados obtenidos en la muestra de entrenamiento o de estimación, formada por el restante 80% de las observaciones (2.895 empresas). Todos los indicadores de rendimiento y de precisión del modelo obtenidos a través del algoritmo *XGBoost* de *machine learning* incluidos en este estudio se han obtenido a partir de la referida muestra independiente de comprobación.

3.3. Selección y definición de las variables explicativas

Entre los aspectos más relevantes en la elaboración de modelos de predicción o de clasificación del fracaso empresarial se encuentra la selección de las variables independientes, que en nuestro caso serán, fundamentalmente, ratios económico-financieros.

Dado que no hay una teoría determinada que fije el proceso de selección de estas variables, lo cual constituye una limitación a la hora de modelizar el fracaso empresarial, hemos tratado de conciliar la experiencia aportada por parte de otros autores como Tascón y Castaño (2012), que analizan con detalle las variables utilizadas en los principales estudios sobre predicción del fracaso empresarial.

La lista y descripción de las variables consideradas inicialmente y separadas por categorías la mostramos en la tabla 3.

Tabla 3. Variables explicativas

CLAVE	VARIABLES
RATIOS DE RENTABILIDAD	
RSHF	ROE (base RAI) (%) = $(RAI / Patrimonio\ neto) * 100$
RCEM	ROCE (base RAI) (%) = $[(RAI + Gtos\ financ.) / (Recursos\ permanentes)] * 100$
RTAS	ROA (base RAI) (%) = $(RAI / Activo\ total) * 100$
ROE	ROE (base Ingresos netos) (%) = $(Resultado\ neto / Patrimonio\ neto) * 100$
ROCE	ROCE (base Rdo neto) (%) = $[(RAI) / Recursos\ Permanentes] * 100$
ROA	ROA (base Ingresos Netos) (%) = $(Resultado\ neto / Activo\ total) * 100$
PRMA	Margen de beneficio (%) = $(RAI / Resultado\ de\ explotación) * 100$
ETMA	Mg EBITDA % = $(EBITDA / Resultado\ de\ explotación) * 100$
EBMA	MG EBIT (%) = $(EBIT / Resultado\ de\ explotación)$
CFOP	Cash flow operativo (%) = $(Flujo\ de\ caja / Resultado\ de\ explotación) * 100$
RATIOS OPERATIVOS	
NAT	Rotación de activos netos = $Resultado\ de\ explotación / (Rec.\ permanentes)$
COLL	Período de Cobro (días) = $(Deudores / Resultado\ de\ explotación) * 360$
CRPE	Período de Crédito (días) = $(Acreedores / Resultado\ de\ explotación) * 360$
RATIOS ESTRUCTURALES	
CURR	Ratio Corriente = $(Activo\ corriente / Pasivo\ corriente)$
LIQR	Ratio de Liquidez = $(Activo\ corriente - Existencias) / Pasivo\ corriente$
SOLL	Ratio de solvencia (%) = $(Patrimonio\ neto / Activo\ Total) * 100$
GEAR	Coef. Endeud.(%) = $[(Pasivo\ no\ corriente + Préstamos) / Pat.\ neto] * 100$
RCD	Ratio de Calidad de la Deuda = $Pasivo\ corriente / Pasivo\ Total$
RATIOS POR EMPLEADO	
PPE	Beneficio por empleado = $RAI / n^{\circ}\ empleados$
TPR	Rdo de explotación por empleado = $Resultado\ de\ explotación / n^{\circ}\ empleados$

SCT	$(\text{Gastos de personal} / \text{Resultado de explotación}) * 100$
ACE	$\text{Coste medio de los empleados} = \text{Gastos de personal} / \text{n}^\circ \text{empleados}$
SFPE	$\text{Fondos propios por empleado} = \text{Patrimonio neto} / \text{n}^\circ \text{empleados}$
WCPE	$\text{Capital corriente por empleado} = \text{Capital corriente} / \text{n}^\circ \text{empleados}$
TAPE	$\text{Total de activos por empleado} = \text{Activo total} / \text{n}^\circ \text{empleados}$

Nota: Clave basada en la referencia que aparece en la base de datos ORBIS (2021).

Fuente: Elaboración propia a partir de información obtenida de la base de datos ORBIS (2021).

Las 25 variables explicativas inicialmente seleccionadas, tras descartar previamente algunas por presentar demasiados valores perdidos, han sido consideradas en la aplicación del algoritmo *XGBoost* para tratar de identificar las que resultan más relevantes para identificar las empresas más propensas al fracaso empresarial, tal como describimos en el siguiente apartado.

4.- METODOLOGÍA

El objetivo de este trabajo es desarrollar un modelo de clasificación utilizando técnicas del aprendizaje automático, en particular haremos uso del algoritmo *XGBoost*. Como ya hemos recogido anteriormente, la base de datos ORBIS nos ha permitido disponer del indicador de fortaleza financiera VADIS, de forma que a partir de éste hemos identificado un total de 1.800 empresas con una propensión no alta al fracaso y 1.809 empresa con una propensión muy alta al fracaso, sumando un total de 3.609 empresas. Es muy importante que el modelo desarrollado no incurra en un problema de sobre-ajuste (*overfitting*, en inglés) y resulte generalizable a la utilización de nuevos datos. Chen y Guestrin (2016) resaltan que *XGBoost* es una implementación eficiente y escalable del algoritmo *gradient boosting* de Friedman (Friedman, 2001 y Friedman et al. 2000). Uno de los elementos que caracteriza a los algoritmos basados en el *gradient boosting* es que la creación de los árboles de decisión se realiza de modo secuencial, de forma que cada uno de los nuevos árboles se construye con el fin de corregir los errores de los anteriores.

El uso de esta metodología produce resultados de predicción muy elevados, como así ha quedado constatado en los recientes trabajos de Climent et al. (2019) y Carmona et al. (2019), que tenían como finalidad la predicción del fracaso bancario tanto en Europa como en U.S.A.

En realidad, el algoritmo *XGBoost* produce un conjunto de modelos simples basado en árboles de decisión, de modo que la adición de éstos mejora considerablemente la capacidad predictiva de los árboles de decisión individuales que forman el referido conjunto. Otra

característica de un modelo *XGBoost* es que incorpora en la construcción de los árboles de decisión lo que se conocen dentro del aprendizaje automático como regularización, lo que supone una implementación de un mecanismo de control del peso que tienen las variables en el modelo final; esto supone un elemento diferenciador respecto a otros algoritmos similares basados también en *gradient boosting*, y conlleva una importante reducción en la posibilidad de desarrollar modelos que no resulten generalizables sobre datos independientes.

Como ya se ha indicado disponemos de un total de 3.609 observaciones de empresas, lo que constituye la muestra inicial. Para aplicar correctamente las técnicas de aprendizaje automático, hemos dividido estas observaciones en dos grupos, el primero constituye la muestra de entrenamiento (2.895 observaciones, aproximadamente el 80%) y el segundo la muestra de comprobación (714 observaciones, aproximadamente el 20%). Nos valdremos del primer grupo o muestra de entrenamiento precisamente para entrenar el algoritmo *XGBoost* y, posteriormente, una vez identificado el mejor de los modelos nos valdremos de la muestra de comprobación, que es una muestra independiente y que no se ha utilizado para entrenar al algoritmo, para cerciorarnos de que los resultados son válidos y, por tanto, generalizables.

La obtención del mejor de los modelos *XGBoost* para el conjunto de datos disponibles requiere la identificación de los valores óptimos de los denominados hiper-parámetro (*hyperparameters*, en inglés). Para ello, es necesario un proceso de iteración entre las diferentes combinaciones de valores que pueden tomar estos hiperparámetros con el fin de aislar la mejor de todas estas combinaciones, de modo que permita construir un modelo con una alta capacidad predictiva. A continuación, hacemos referencia a los principales hiper-parámetros propios del algoritmo *XGBoost*:

- Número de vueltas o pasadas sobre los datos que necesita el algoritmo. En cada vuelta se construye un árbol de decisión individual. En general, hay un límite de pasadas a partir del cual el modelo resultante no mejora.
- Profundidad máxima de los árboles de decisión individuales. Cuanto menor sea los árboles tienen una menor capacidad de captar las características de los datos, pero un valor alto puede producir problemas de sobreajuste.
- Ratio de aprendizaje o contribución de cada árbol en el crecimiento del modelo. Determina la rapidez con la que el algoritmo incorpora o adapta la contribución de cada árbol al modelo en construcción en cada iteración. Se recomiendan valores pequeños para que el crecimiento sea muy lento y evitar así problemas de sobreajuste.

- Gamma o reducción de pérdida mínima para que el algoritmo realice una partición adicional. Cuando la reducción de la función de pérdida está por debajo del valor indicado no se realizan más particiones de los árboles de decisión. Este parámetro controla la regularización del modelo, cuanto más alto sea el valor especificado mayor es la regularización.
- Ratio del porcentaje de las variables y observaciones que intervienen en la construcción de cada árbol.
- Número mínimo de observaciones necesarias en cada nodo terminal. Cuanto mayor sea esta cantidad el algoritmo resultará más conservador, en el sentido de que será más flexible y robusto a problemas de sobreajuste.

Para la identificación de la mejor combinación posible de todos estos hiper-parámetros es muy habitual entre los profesionales del aprendizaje automático hacer uso de las técnicas de validación cruzada. En particular, la validación cruzada se ha decidido realizarla con 10 submuestras ($k=10$), por lo que el proceso de entrenamiento del algoritmo *XGBoost* consiste en el ajuste de 10 modelos sobre 9 submuestras diferentes (cada una con el 90% de las observaciones), de forma que la estimación de la bondad del ajuste final se ha obtenido a partir de la media de los resultados obtenidos en el 10% restante de cada una de las 10 submuestras. Asimismo, para identificar una buena combinación de hiper-parámetros que proporcione un modelo muy robusto y con una alta capacidad predictiva, se ha recurrido a lo que se conoce como búsqueda aleatoria; es decir, entre todas las disposiciones posibles del espacio de búsqueda especificado se han elaborado 25 modelos, correspondientes a 25 posibles combinaciones aleatorias, que en realidad son 250 (25×10) debido a la validación cruzada seguida de 10 submuestras.

Como se ha indicado, la totalidad de los datos disponibles sobre las empresas consideradas se ha dividido en dos grupos. Por un lado, la muestra de entrenamiento con un 80% de las observaciones, la cual se ha empleado para entrenar el algoritmo *XGBoost* y así identificar una buena combinación de hiper-parámetros que permitan la obtención de un modelo final con una alta capacidad predictiva. Y por otro lado el 20% restante, que como muestra de comprobación independiente se ha utilizado para validar el modelo final y obtener las métricas de rendimiento del mismo.

Para implementar el algoritmo *XGBoost* se ha empleado el entorno de programación estadístico *R* (R Core Team, 2021) y la librería *h2o* (LeDell et al., 2020).

MODELO XGBOOST CON TODAS LAS VARIABLES

De acuerdo con la metodología descrita, hemos construido un modelo *XGBoost* que incorpora todas las variables recogidas en la tabla 3, con la finalidad de identificar las variables más relevantes y que, por tanto, son determinantes para clasificar a una empresa con una alta probabilidad de incurrir en una situación de quiebra en un futuro próximo. Como es habitual en los escenarios de clasificación en el aprendizaje automático, hemos considerado el indicador AUC (*area under the curve* o área bajo la curva en español) para identificar el mejor de los modelos ajustados de acuerdo con las diferentes combinaciones de hiper-parámetros. Esta métrica pone en comparación la ratio de falsos positivos con la ratio de verdaderos positivos. De modo intuitivo, esta área viene a representar la probabilidad de que una compañía con alta propensión a la quiebra seleccionada de forma aleatoria, tenga una probabilidad mayor de resultar clasificada por el modelo final como efectivamente con una alta propensión a la quiebra. El valor máximo que puede tomar este indicador es de 1 y cuanto más alto sea mejor el modelo resultante.

Como ya se ha indicado se han construido 25 modelos primarios *XGBoost*, correspondientes a 25 posibles combinaciones de hiper-parámetros, y sus correspondientes modelos de validación cruzada. Se ha seleccionado como modelo final aquél con un mayor indicador AUC sobre las muestras de validación cruzada, que alcanzó un valor de 0,99, muy próximo al valor máximo de 1; este modelo obtuvo una precisión global del 96%, también sobre las muestras de validación cruzada. En la tabla 4 recogemos los valores que toman los hiper-parámetros para este modelo.


Tabla 4. Valores óptimos de los hiper-parámetros del modelo *XGBoost*

Número de pasadas del algoritmo	60
Profundidad máxima	12
Ratio de aprendizaje	0,19
Gamma	0,001
Porcentaje de variables	46%

Porcentaje de observaciones	70%
Mínimo observaciones nodo terminal	2

En la figura 1 mostramos las variables que tienen una mayor importancia en la construcción de este modelo *XGBoost* para la clasificación de las empresas que tienen una propensión muy alta a incurrir en los 18 meses siguientes en una situación de quiebra. Para este tipo de modelos de predicción basados en el algoritmo *gradient boosting*, y con el fin de identificar las variables más importantes, se toma en consideración la ganancia que incorpora cada variable en cada uno de los árboles que se construyen y, entonces, se promedia entre todas las variables para obtener una visión global del modelo en su conjunto (Chen y Guestrin, 2016). Las cuatro primeras variables de la figura 1 son las que tienen una mayor importancia: SOLL, RTAS, ROA y GEAR.

Figura 1. Variables más relevantes del modelo de clasificación *XGBoost*



A continuación, nos valemos de los gráficos de dependencia parcial para representar la relación entre las variables más relevantes y la propensión de una empresa al fracaso. Se trata de medidas de interpretación global del modelo que ayudan a comprender las relaciones existentes entre los inputs del modelo y el output o variable dependiente (Hall y Gill, 2019). Este tipo de representaciones ayudan a entender el proceso que sigue un modelo para realizar predicciones de acuerdo con la importancia de las variables detectadas y con la influencia que

ejercen en la estructura del modelo. Estos gráficos de dependencia muestran la respuesta del modelo como función de una de las variables independientes, como media de todas las observaciones (Biecek y Burzycowski, 2020).

La figura 2 recoge los gráficos de dependencia parcial de las cuatro variables identificadas como más relevantes. Adicionalmente en la figura 3 se muestra la representación conjunta de la distribución y diagrama de caja de la variable más importante, SOLL, tanto para las empresas con una propensión alta a la quiebra como para las que tienen una propensión no alta.




Los gráficos de dependencia parcial de las cuatro variables más importantes recogidos en la figura 2, ilustran el efecto marginal de cada variable por separado en la probabilidad de que una empresa pueda ser considerada como propensa al fracaso. El eje de las abscisas nos muestra los valores que pueden tomar las variables y el eje de ordenadas nos muestra la probabilidad de fracaso de la entidad.

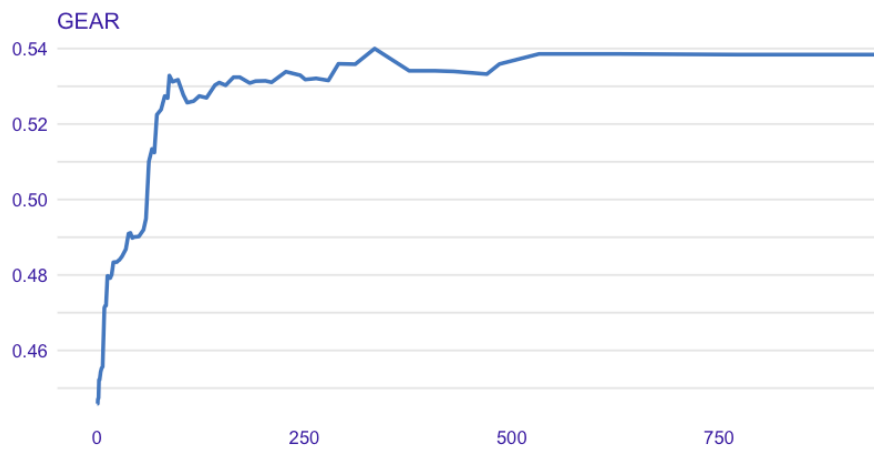
La curva descendente del gráfico correspondiente a la variable SOLL indica que conforme aumenta la solvencia de la entidad disminuye su propensión a su fracaso. Este resultado es totalmente coherente, ya que si la entidad puede hacer frente a sus deudas es razonable que disminuya la posibilidad de que entre en fase de dificultad financiera que la aboque a su fracaso.

Los gráficos descendentes de las variables RTAS y ROA de la figura 2, indican que cuanto mayor es su valor, menor es la propensión al fracaso. Estas variables aumentan cuando crece el RAI o el Resultado neto, respectivamente, en relación con el activo de la entidad, resultando razonable que cuando una empresa sea más rentable se reduzca su propensión al fracaso.

Finalmente, atendiendo al gráfico ascendente que presenta la variable GEAR de la figura 2, que analiza el endeudamiento de la empresa, se observa que a medida que incrementa su valor también aumentan las posibilidades de fracaso. La ratio GEAR se incrementa si lo hacen la financiación ajena, por lo que un importe elevado mostraría un excesivo endeudamiento respecto a la financiación propia, lo que favorecería que surgieran problemas en la empresa, siendo coherente, por tanto, que valores altos de dicha variable se asocie con una mayor propensión al fracaso de la entidad.


Figura 2. Gráficos de dependencia parcial





NOTA: el eje de las ordenadas representa la probabilidad de la propensión a la quiebra

Figura 3. Representación conjunta de la distribución y diagrama de caja de la variable SOLL

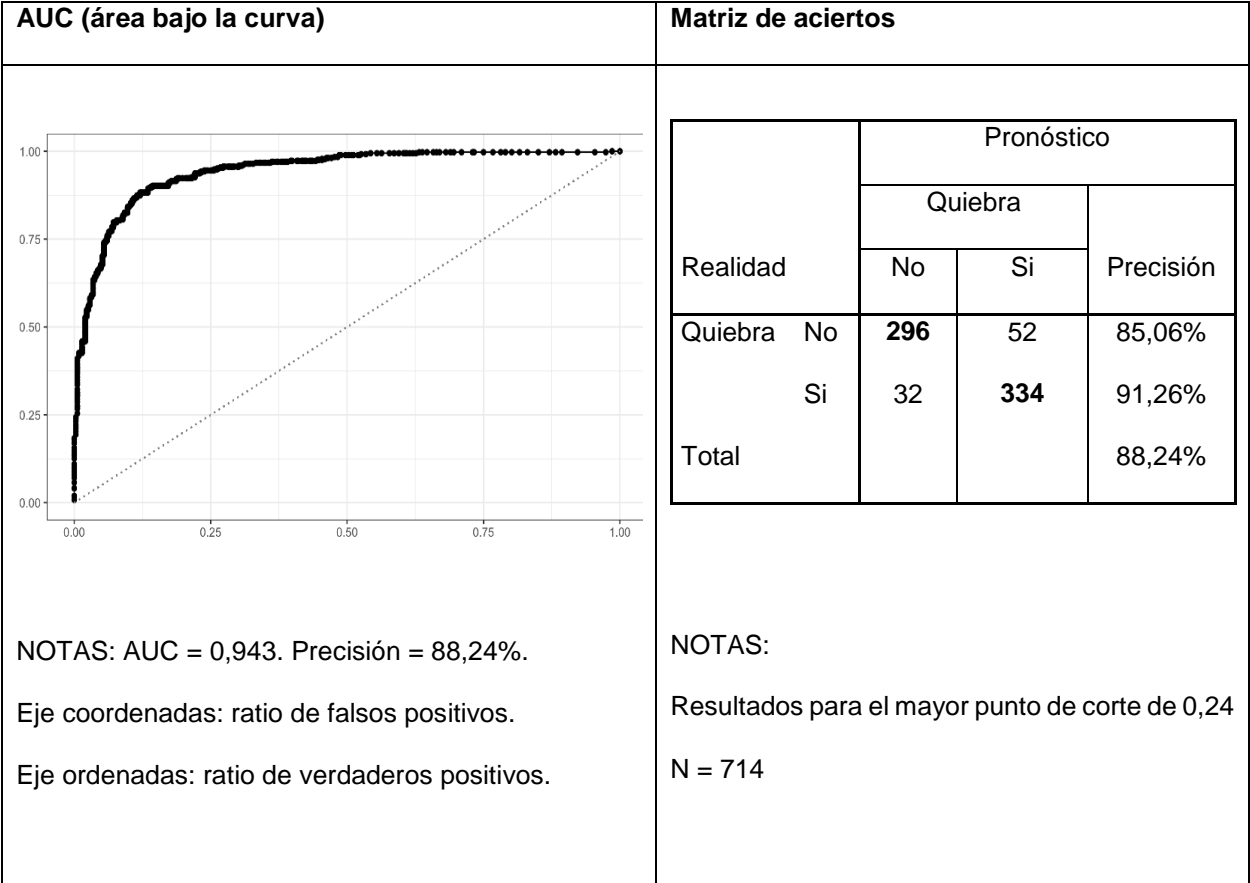


Validación del modelo en la muestra de comprobación

A continuación, vamos a comprobar la capacidad de predicción que tiene este modelo sobre una muestra independiente de datos o muestra de comprobación. Para tal efecto, y para esta

muestra de comprobación, véase la figura 4, hemos obtenido los valores de predicción del modelo de clasificación ajustado *XGBoost* y los hemos comparado con los valores reales, obteniendo un nivel de precisión global del 88% y un valor del área bajo la curva (*AUC*) de 0,943 —muy próximo al valor máximo de 1 que puede alcanzar—. Por consiguiente, a la vista de estos resultados, podemos concluir que el modelo *XGBoost* identificado no presenta problemas de sobreajuste y se puede generalizar y aplicar sobre muestras independientes.

Figura 4. Resultados del modelo *XGBoost* en la muestra de comprobación

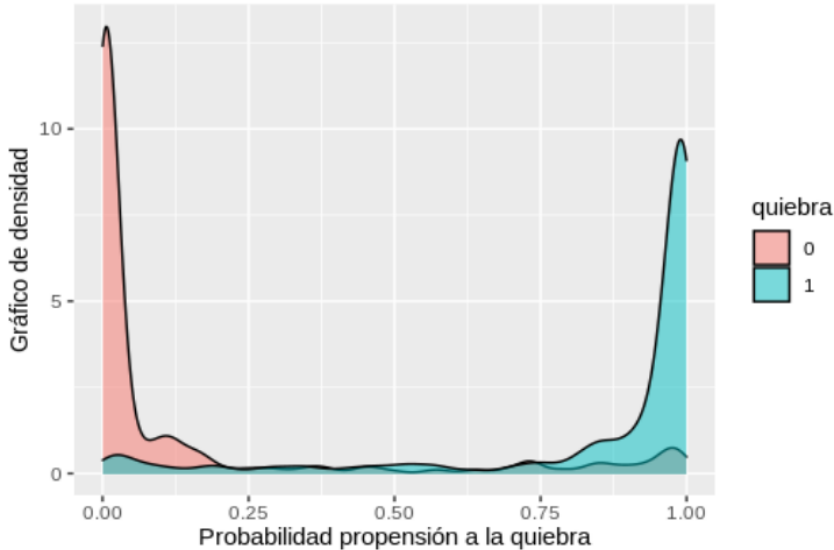


Asimismo, en la figura 5 se muestra la función de densidad de las probabilidades de incurrir en una situación de quiebra durante los próximos meses que genera el modelo, separando

entre empresas con una tendencia real alta hacia la quiebra y las que tienen una tendencia real baja, de acuerdo con la calificación que otorga VADIS, y sobre los datos de la muestra de comprobación. Se observa, que el modelo *XGBoost* estimado es capaz de separar muy bien entre las empresas con una alta propensión a la quiebra y las que no tienen esa alta propensión, de forma que es posible dibujar una línea vertical imaginaria que diferencie claramente estos dos grupos.

En definitiva, los altos valores obtenidos en la muestra de comprobación en cuanto a la precisión global del modelo y del área bajo la curva, así como la representación gráfica de las probabilidades de fracaso, confirman que los resultados conseguidos con el algoritmo *XGBoost* en la muestra de entrenamiento, se pueden extrapolar o generalizar sobre muestras independientes. En gran medida, el uso de la aludida técnica del aprendizaje automático de validación cruzada ha posibilitado la identificación de un modelo robusto.

Figura 5. Gráficos de densidad de la distribución de la probabilidad de quiebra del modelo *XGBoost* (muestra de comprobación)



NOTAS: 1 indica una alta propensión a la quiebra y 0 una no alta propensión a la quiebra

Efecto de las variables en las predicciones del modelo a nivel de observaciones individuales

Por último, vamos a mostrar cómo es posible llegar a un nivel de interpretación del modelo *XGBoost* que nos permita conocer el efecto que tienen las variables sobre cada una de las observaciones tomadas de forma individual. Para ilustrarlo vamos a considerar dos observaciones a las que el modelo asigna una probabilidad muy alta de quiebra en los próximos meses (figura 6) y también el caso opuesto, esto es, dos observaciones con una probabilidad muy baja (véase dos últimos gráficos de la figura 7).

Estas representaciones se encuadran en lo que se conoce como interpretación local de un modelo, y ayudan a comprender un modelo de aprendizaje automático y sus predicciones para observaciones individuales (Hall y Gill, 2019). En este sentido, resulta muy interesante o incluso en ocasiones necesario evaluar el efecto de las variables independientes en las predicciones que proporciona un modelo para una observación determinada. En particular, en este estudio, el investigador o un analista financiero podría estar interesado en comprender las razones por las cuales el algoritmo *XGBoost* clasifica una empresa dada como propensa a entrar en una situación de quiebra en los próximos meses, a partir de los valores que toman las variables independientes en esta empresa. Todo ello, permitirá mostrar implicaciones éticas de los resultados obtenidos, de modo que las predicciones individuales son totalmente transparentes y se supera los límites de la denominada “caja negra”.

Por consiguiente, con el fin de mostrar el funcionamiento del modelo obtenido con el algoritmo *XGBoost* puede resultar apropiado encontrar algún tipo de explicación que identifique cuáles son las variables que más influyen en la predicción de cualquiera de las empresas. Esto es, calcular la contribución de las variables independientes que tienen un mayor peso en estas predicciones (Biecek y Burzycowski, 2020).

En el aprendizaje automático, los denominados gráficos de descomposición (*break down plots*, en inglés) proporcionan precisamente una manera muy sencilla de resumir el efecto de cada uno de los predictores en la variable explicada del modelo. De este modo, para una observación en particular, la probabilidad de que una empresa resulte propensa a una situación de quiebra se descompone en los distintos impactos correspondientes a cada una de las variables del modelo. Las aludidas figuras 6 y 7 contienen estos gráficos de descomposición.

En estas figuras se aprecia que el modelo base (*intercept*, en inglés) concede una probabilidad general de quiebra del 51,60% (0,516), que es la que se obtiene sin tener en cuenta la capacidad predictiva de los predictores, y representa la proporción de empresas clasificadas por el modelo *XGBoost* con un riesgo de quiebra alto respecto del total de empresas incluidas en la base de datos —la media de las predicciones—. Por ejemplo, para la primera compañía

de la figura 6, la predicción de fracaso arroja una probabilidad de un 100,00% (1,00), la cual se puede descomponer para reflejar la influencia de las variables más relevantes como sigue:

- + 0,516: Modelo base (Intercept)
- + 0,228: RTAS = -39,13 (Rentabilidad económica) [ahora la predicción es 0,744]
- + 0,073: ROA = -2987 (Resultado neto / Activo total) [ahora la predicción es 0,817]
- + 0,182: SOLL = 17,76 (Ratio de solvencia) [ahora la predicción es 0,999]
- + 0,001: GEAR = 232,2 (Coeficiente de endeudamiento) [ahora la predicción es 1]

En general, en estos gráficos aportados a modo de ejemplo se aprecia que valores bajos de solvencia y rentabilidad y valores altos de endeudamiento empujan al modelo de predicción a asignar valores altos en la probabilidad de que una empresa entre en una situación de quiebra en los próximos meses. Sin embargo, valores opuestos a los anteriores, permiten obtener cifras muy bajas en la estimación de la propensión a la quiebra.

Figura 6. Gráfico de descomposición para dos observaciones con una probabilidad muy alta de quiebra de acuerdo con el modelo XGBoost


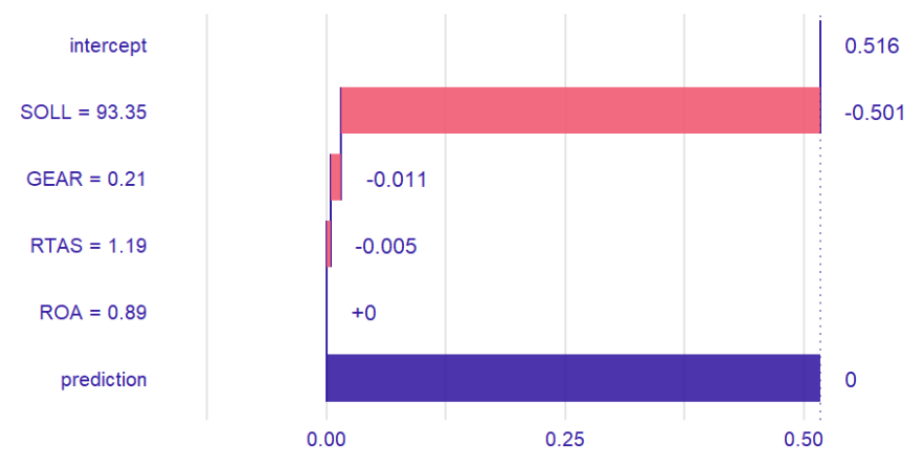





Figura 7. Gráfico de descomposición para dos observaciones con una probabilidad muy baja de quiebra de acuerdo con el modelo XGBoost



5. CONCLUSIONES

Este trabajo basado en la metodología del algoritmo de aprendizaje automático Extreme Gradient Boosting (XGBoost) ha permitido identificar las variables más relevantes que anticipan situaciones de propensión al fracaso y, simultáneamente, interpretar los resultados obtenidos de una forma totalmente transparente.

Como consecuencia de mecanismos internos ocultos estos modelos están etiquetados como cajas negras. Tratamos de explicar qué sucede en el interior de estas cajas negras mediante la identificación de las variables explicativas más relevantes, los gráficos de dependencia parcial a nivel individual de dichas variables y los gráficos de descomposición de las observaciones.

En nuestro estudio se abren estas cajas negras y, utilizando técnicas de *Machine Learning*, particularmente con el uso del algoritmo *XGBoost*, identificamos los indicadores más críticos que caracterizan la propensión al fracaso empresarial

Hemos utilizado el indicador de fortaleza financiera VADIS P2BB como criterio para discernir entre empresas propensas al fracaso y empresas no propensas. Las primeras son aquellas que obtienen una calificación alta en el indicador (9 y 8) y las segundas las que obtienen una calificación baja (1 a 5).

Los resultados derivados del estudio estadístico muestran la relevancia conjunta de las categorías de solvencia, endeudamiento y rentabilidad. El modelo resultante permite identificar la propensión al fracaso empresarial que alcanza con un porcentaje de acierto del 88% en una muestra de comprobación independiente.

El modelo considera como variables más relevantes SOLL, RTAS, ROA y GEAR. La primera es indicativa de la solvencia de la entidad, de su capacidad para hacer frente a los pagos derivados de sus deudas. El estudio confirma que a medida que aumenta la solvencia de la entidad disminuye su propensión al fracaso. Por su parte, la variable GEAR, que nos ofrece

una medida del endeudamiento de la entidad, refleja que si su valor aumenta las probabilidades de fracaso también lo hacen. Finalmente, el estudio muestra que disminuiría la propensión al fracaso si aumenta el valor de las variables RTAS y ROA, representativas de la rentabilidad de la sociedad en relación con su tamaño. De este modo, el hecho de que conforme una empresa tenga mejores resultados reduzca la propensión al fracaso, al ser más rentable, resulta también coherente.

Estos resultados son consecuentes con la evidencia empírica, por lo que entendemos que la técnica aplicada es perfectamente válida para los objetivos perseguidos, que no son otros que la detección de la propensión al fracaso empresarial y mostrar el contenido oculto de los algoritmos. El modelo resultante, además de clasificar a las empresas en propensas al fracaso o no propensas, permite determinar los motivos de dicha clasificación de forma local.

Para una observación en particular, la probabilidad de que una empresa resulte o no propensa a una situación de propensión al fracaso la descomponemos en los distintos impactos correspondientes a cada una de las variables del modelo, separando el peso individual de cada uno de los predictores, al tiempo que recoge su signo. De este modo, se constata que los resultados demuestran una alta capacidad predictiva y son totalmente interpretables, es decir, es posible determinar el signo y el efecto de cada una de las variables sobre la propensión al fracaso de todas y cada una de las observaciones.

Entendemos que los modelos planteados desde el punto de vista ético son autónomos pues el razonamiento y el consecuente proceso de toma de decisiones se apoya en una programación previa lo que nos hace pensar que la responsabilidad ética derivada del uso de estas tecnologías se imputa directamente a las personas y no a los modelos que se utilizan.

Dada la bondad del modelo obtenido y su sencilla interpretabilidad, podría ser de utilidad a los diferentes usuarios para detectar situaciones de propensión al fracaso y facilitar así la toma de decisiones oportunas.

Finalmente, nos gustaría dar al estudio un carácter de continuidad pues consideramos interesante incidir en este tipo de análisis aplicándolo a nuevas muestras específicas por áreas sectoriales o geográficas.

BIBLIOGRAFÍA

Alfaro, E., García, N., Gámez, M., & Elizondo, D. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*, 45(1), 110-122. doi:10.1016/j.dss.2007.12.002

Altman, E. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *23*(4), 589-609.

Berryman, J. E. (1993). Small Business Failure and Bankruptcy: What Progress Has Been Made in a Decade? *Small Enterprise Research*, *2*(1-2), 5-27. doi:10.5172/ser.2.1-2.5

Biecek, P. (2018). Dalex: Explainers for complex predictive models in R. *Journal of Machine Learning Research*, *19*. 19(84), 1-5. URL: <http://jmlr.org/papers/v19/18-416.html>.

Biecek, P., & Burzykowski, T. (2021). Explanatory Model Analysis. [Pbiecek.github.io](https://pbiecek.github.io). Available at: <https://pbiecek.github.io/ema/preface.html> [Accessed 21 Sep. 2020].

Boehmke, B., & Greenwell, B. (2020). *Hands-On Machine Learning with R*. CRC Press. Taylor & Francis Group. Florida (USA).

Boubaker, S., Buchanan, B., & Nguyen, D. K. (2016). *Risk Management in Emerging Markets: Issues, Framework, and Modeling*: Emerald Group Publishing.

Carmona, P., Climent, F., & Momparler, A. (2019). Predicting failure in the US banking sector: An extreme gradient boosting approach. *International Review of Economics & Finance*, *61*, 304-323. <https://doi.org/10.1016/j.iref.2018.03.008>

Carvalho, D. V., Pereira, E. M., & Cardoso, J. S. (2019). Machine learning interpretability: A survey on methods and metrics. In (Vol. 8).

Chen, T., & Guestrin, C. (2016, 2016). XGBoost: A scalable tree boosting system. arXiv:1603.02754v3 [cs.LG]

Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Zhou, T. (2019). Xgboost: Extreme gradient boosting. R package version 0.90. 0.2. In.

Carmona, P., Dwekat, A., Mardawi, (2022), Z.: No more black boxes! Explaining the predictions of a machine learning XGBoost classifier algorithm in business failure, *Research in International Business and Finance*, *61*. <https://doi.org/10.1016/j.ribaf.2022.101649>.

Climent, F., Momparler, A., & Carmona, P. (2019). Anticipating bank distress in the Eurozone: An Extreme Gradient Boosting approach. *Journal of Business Research*, *101*, 885-896. doi:10.1016/j.jbusres.2018.11.015

Cortés, E. A., Martínez, M. G., & Rubio, N. G. (2008). FIAMM return persistence analysis and the determinants of the fees charged. *Spanish Journal of Finance and Accounting / Revista Española de Financiación y Contabilidad*, *37*(137), 13-32. doi:10.1080/02102412.2008.10779637

Cran.r-project.org. (2020). Introducing Correlation Funnel - Customer Churn Example. Retrieved from https://cran.r-project.org/web/packages/correlationfunnel/vignettes/introducing_correlation_funnel.html

Davies, D. (1997). *Art of Managing Finance* (Third ed.). NEW YORK: McGraw-Hill.

Doshi-Velez, F., & Kim, B. (2017). A Roadmap for a Rigorous Science of Interpretability. arXiv preprint arXiv:1702.08608v1, 1-13.

Du Jardin, P. (2016). A two-stage classification technique for bankruptcy prediction. *European Journal of Operational Research*, 254(1), 236-252. doi:10.1016/j.ejor.2016.03.008

Du Jardin, P. (2017). Dynamics of firm financial evolution and bankruptcy prediction. *Expert Systems with Applications*, 75, 25-43. doi:10.1016/j.eswa.2017.01.016

Eling, M., & Jia, R. (2018). Business failure, efficiency and volatility: Evidence from the European insurance industry. *International Review of Financial Analysis*, 59, 58-76. doi:10.1016/j.irfa.2018.07.007

Elith, J., Leathwick, J. R., & Hastie, T. (2008). A working guide to boosted regression trees. In (Vol. 77, pp. 802-813).

Erdogan, B. E. (2013). Prediction of bankruptcy using support vector machines: An application to bank bankruptcy. *Journal of Statistical Computation and Simulation*, 83(8). doi:10.1080/00949655.2012.666550

Faccia, A., Manni, F., & Capitanio, F. (2021). Mandatory esg reporting and xbrl taxonomies combination: Esg ratings and income statement, a sustainable value-added disclosure. *Sustainability (Switzerland)*, 13(16). doi:10.3390/su13168876

Faccia, A., & Petratos, P. (2021). Blockchain, enterprise resource planning (ERP) and accounting information systems (AIS): Research on e-procurement and system integration. *Applied Sciences (Switzerland)*, 11(15). doi:10.3390/app11156792

Fisher, A., Rudin, C., & Dominici, F. (2018). Model Class Reliance: Variable Importance Measures for any Machine Learning Model Class, from the "Rashomon" Perspective. *Journal of Machine Learning Research*, 20.

Foster, D. (2017). NEW R package that makes XGBoost interpretable. Retrieved from <https://medium.com/applied-data-science/new-r-package-the-xgboost-explainer-51dd7d1aa211>

- Friedman, J. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232. doi:10.1214/aos/1013203451
- Friedman, J. (2002). Stochastic gradient boosting. *Computational Statistics and Data Analysis*, 38(4), 367-378. doi:10.1016/S0167-9473(01)00065-2
- Friedman, J., Hastie, T., & Tibshirani, R. (2000). Additive logistic regression: A statistical view of boosting (with discussion and a rejoinder by the authors). *The Annals of Statistics*, 28(2), 337-407.
- Gilpin, L. H., Bau, D., Yuan, B. Z., Bajwa, A., Specter, M., & Kagal, L. (2018). Explaining Explanations: An Approach to Evaluating Interpretability of Machine Learning. arXiv:1806.00069, 1-11.
- Hall, P., & Gill, N. (2019). *An introduction to machine learning interpretability* (2nd Edition ed.). Sebastopol, CA, USA: O'Reilly Media, Incorporated.
- Hosaka, T. (2019). Bankruptcy prediction using imaged financial ratios and convolutional neural networks. *Expert Systems with Applications*, 117. doi:10.1016/j.eswa.2018.09.039
- Jabeur, S. B., Gharib, C., Mefteh-Wali, S., & Arfi, W. B. (2021). CatBoost model and artificial intelligence techniques for corporate failure prediction. *Technological Forecasting and Social Change*, 166. doi:10.1016/j.techfore.2021.120658
- Jones, S. (2017). Corporate bankruptcy prediction: a high dimensional analysis. *Review of Accounting Studies*, 22(3), 1366-1422. doi:10.1007/s11142-017-9407-1
- Kalak, I. E., Azevedo, A., Hudson, R., & Karim, M. A. (2017). Stock liquidity and SMEs' likelihood of bankruptcy: Evidence from the US market. *Research in International Business and Finance*, 42. doi:10.1016/j.ribaf.2017.07.077
- Khoja, L., Chipulu, M., & Jayasekera, R. (2019). Analysis of financial distress cross countries: Using macroeconomic, industrial indicators and accounting data. *International Review of Financial Analysis*, 66. doi:10.1016/j.irfa.2019.101379
- Kim, H. J., Jo, N. O., & Shin, K. S. (2016). Optimization of cluster-based evolutionary undersampling for the artificial neural networks in corporate bankruptcy prediction. *Expert Systems with Applications*, 59, 226-234. doi:10.1016/j.eswa.2016.04.027
- Le, H. H., & Viviani, J. L. (2018). Predicting bank failure: An improvement by implementing a machine-learning approach to classical financial ratios. *Research in International Business and Finance*, 44. doi:10.1016/j.ribaf.2017.07.104

- LeDell, E., Gill, N., Aiello S. et al. (2021). h2o: R Interface for the 'H2O' Scalable Machine Learning Platform. R package version 3.32.1.3. <https://CRAN.R-project.org/package=h2o>.
- Lee, S., & Choi, W. S. (2013). A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40(8), 2941-2946. doi:10.1016/j.eswa.2012.12.009
- Momparler, A., Carmona, P., & Climent, F. (2016). La Predicción Del Fracaso Bancario Con La Metodología “Boosting Classification Tree”. *Revista Espanola de Financiacion y Contabilidad*, 45(1), 63-91. doi:10.1080/02102412.2015.1118903
- Momparler, A., Carmona, P., & Climent, F. (2020). Revisiting bank failure in the United States: a fuzzy-set analysis. *Economic Research-Ekonomiska Istrazivanja*, 33(1), 3017-3033. doi:10.1080/1331677X.2019.1689838
- Monasterio Astobiza, A. (2017). Ética algorítmica: Implicaciones éticas de una sociedad cada vez más gobernada por algoritmos. *Dilemata*, (24), 185–217. Recuperado a partir de <https://www.dilemata.net/revista/index.php/dilemata/article/view/412000107>
- Mosteanu, N. R., & Faccia, A. (2020). Digital systems and new challenges of financial management – fintech, XBRL, blockchain and cryptocurrencies. *Quality - Access to Success*, 21(174).
- Mousavi, M. M., Ouenniche, J., & Xu, B. (2015). Performance evaluation of bankruptcy prediction models: An orientation-free super-efficiency DEA-based framework. *International Review of Financial Analysis*, 42, 64-75. doi:10.1016/j.irfa.2015.01.006
- Mselmi, N., Lahiani, A., & Hamza, T. (2017). Financial distress prediction: The case of French small and medium-sized firms. *International Review of Financial Analysis*, 50, 67-80. doi:10.1016/j.irfa.2017.02.004
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, 7, 21.
- ORBIS (2021). Base de datos de Bureau Van Dijk. Recuperado en 2021.
- Oyewo, B., Ajibola, O., & Ajape, M. (2020). Characteristics of consulting firms associated with the diffusion of big data analytics. *Journal of Asian Business and Economic Studies*, ahead-of-print(ahead-of-print). doi:10.1108/jabes-03-2020-0018
- R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>

- Pozuelo, J., Martínez, J. & Carmona, P. (2018). Análisis de la utilidad del algoritmo Gradient Boosting Machine (GBM) en la predicción del fracaso empresarial. *Spanish Journal of Finance and Accounting / Revista Española de Financiación y Contabilidad*, 47(4), 507-532. DOI: 10.1080/02102412.2018.1442039.
- Rapanyane, M. B., & Sethole, F. R. (2020). The rise of artificial intelligence and robots in the 4th Industrial Revolution: implications for future South African job creation. *Contemporary Social Science*, 15(4), 489-501. doi:10.1080/21582041.2020.1806346
- Santhanam, G. R., Holland, B., Kothari, S., & Ranade, N. (2017, 2017). Human-on-the-loop automation for detecting software side-channel vulnerabilities.
- Stolbov, M., & Shchepeleva, M. (2020). Systemic risk, economic policy uncertainty and firm bankruptcies: Evidence from multivariate causal inference. *Research in International Business and Finance*, 52. doi:10.1016/j.ribaf.2019.101172
- Syam, N., & Sharma, A. (2018). Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. *Industrial Marketing Management*, 69, 135-146. doi:10.1016/j.indmarman.2017.12.019
- Tascón, M.T. and Castaño, F.J. (2012). Variables y Modelos para la Identificación y Predicción del Fracaso Empresarial: Revisión de la Investigación Empírica Reciente, *Revista de Contabilidad*, 15(1), pp. 7-58. [https://doi.org/10.1016/S1138-4891\(12\)70037-7](https://doi.org/10.1016/S1138-4891(12)70037-7)
- Tian, S., & Yu, Y. (2017). Financial ratios and bankruptcy predictions: An international evidence. *International Review of Economics and Finance*, 51. doi:10.1016/j.iref.2017.07.025
- Tsai, C. F., & Cheng, K. C. (2012). Simple instance selection for bankruptcy prediction. *Knowledge-Based Systems*, 27, 333-342. doi:10.1016/j.knosys.2011.09.017
- Vega García, M., & Aznarte, J. L. (2020). Shapley additive explanations for NO2 forecasting. *Ecological Informatics*, 56. doi:10.1016/j.ecoinf.2019.101039
- Xia, Y., Liu, C., Li, Y. Y., & Liu, N. (2017). A boosted decision tree approach using Bayesian hyper-parameter optimization for credit scoring. *Expert Systems with Applications*, 78, 225-241. doi:10.1016/j.eswa.2017.02.017
- Zhou, L., Si, Y. W., & Fujita, H. (2017). Predicting the listing statuses of Chinese-listed companies using decision trees combined with an improved filter feature selection method. *Knowledge-Based Systems*, 128, 93-101. doi:10.1016/j.knosys.2017.05.003

Zięba, M., Tomczak, S. K., & Tomczak, J. M. (2016). Ensemble boosted trees with synthetic features generation in application to bankruptcy prediction. *Expert Systems with Applications*, 58, 93-101. doi:10.1016/j.eswa.2016.04.001