



# **MÁSTER OFICIAL EN ADMINISTRACIÓN DE EMPRESAS (MBA)**

**CURSO 2018-2019**

## **APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE**

## **APPLICATION OF NEURAL NETWORKS IN THE QUALITY EVALUATION OF ACCOUNTING INFORMATION**

**AUTOR: JAVIER ALEJANDRO CUARTAS MICIECES**

**DIRECTOR: FRANCISCO MANUEL SOMOHANO  
RODRÍGUEZ**

15/02/2019



## **Agradecimientos**

Aprovecho para trasladar mi agradecimiento a todos los profesores del máster MBA por las lecciones, conocimientos y habilidades que nos han ayudado a cultivar a lo largo de este año y en especial a D. Francisco Manuel Somohano Rodríguez, el director del presente trabajo, y a la Cátedra PYME que lidera, por la inspiración, guía y ayuda en su elaboración.

Para terminar, quisiera dar las gracias a mis padres y a mi familia por su apoyo incondicional y siempre presente.

## ÍNDICE

<b>Resumen en español</b> .....	<b>4</b>
<b>Resumen en inglés</b> .....	<b>5</b>
<b>1. Introducción</b> .....	<b>6</b>
<b>2. Justificación</b> .....	<b>9</b>
2.1. <i>Detección de anomalías (outliers)</i> .....	10
<b>3. Objetivo de la investigación</b> .....	<b>12</b>
<b>4. Teoría de Redes Neuronales</b> .....	<b>17</b>
4.1. <i>Concepto y Descripción</i> .....	17
4.2. <i>Aplicación de las redes neuronales</i> .....	20
<b>5. Aplicación a un caso de estudio: el sector de fabricación de muebles en España</b> .....	<b>24</b>
<b>6. Variables del estudio</b> .....	<b>30</b>
<b>7. Análisis y Resultados</b> .....	<b>38</b>
<b>8. Conclusiones y limitaciones</b> .....	<b>55</b>
8.1. <i>Conclusiones</i> .....	55
8.2. <i>Limitaciones</i> .....	58
<b>9. Anexo I. Matriz de Correlaciones</b> .....	<b>59</b>
<b>10. Anexo II. Ratios y resultados del conjunto de prueba</b> .....	<b>61</b>
<b>11. Bibliografía</b> .....	<b>62</b>
<b>12. Webgrafía</b> .....	<b>66</b>

## Resumen en español

La calidad de la información contable se basa en su cumplimiento de ciertas cualidades. Las más importantes de estas son la relevancia o utilidad, y la fiabilidad, por eso, en el estudio del comportamiento de las empresas en un sector económico en general existen una serie de ellas que presentan comportamientos y/o valores anómalos con respecto al grupo principal, que denominamos *outlier*<sup>1</sup>. Su identificación es, a menudo, el punto de partida de muchos estudios. Los analistas y auditores necesitan conjuntos de compañías homogéneas y con poca variabilidad para estudiar el comportamiento general de sus sectores y buscan *outliers* para encontrar errores contables, fraudes, ventajas competitivas, etc.

El objetivo de este trabajo es diseñar y utilizar una herramienta para automatizar esta tarea de detección de anomalías. Los clasificadores de redes neuronales son los elegidos aquí para tratar este problema. La red neuronal es alimentada con un conjunto de compañías cuyas ratios han sido etiquetadas previamente como *outliers* o normales. El resultado es un vector (modelo) con el que el usuario puede clasificar compañías distintas.

Este tema fue elegido por tres razones. Primero, el fraude y el mal reporte de la información contable tienen un efecto muy negativo en compañías, mercados, economía y sociedad. Segundo, las técnicas de inteligencia artificial como las redes neuronales son utilizadas crecientemente con objetivos similares como la detección del fraude y la predicción de quiebra con buenos resultados. Finalmente, la detección de *outliers* es un medio apropiado para identificar la calidad de la información contable, tal y como hemos dicho antes.

Una vez desarrollada, la herramienta se aplicó a un conjunto de empresas reales del sector de fabricación de muebles en España, para comparar diferentes configuraciones respecto a los datos ausentes y a los grados de detalle de la salida. La herramienta fue utilizada para buscar el mejor modelo para cada configuración, probando varios parámetros de diseño de las redes neuronales, relacionados con su complejidad. Además, se imprimieron varios parámetros y gráficas para mostrar el tipo de error que permanecía para el mejor modelo.

El sector de la fabricación de muebles fue elegido por su importancia para la economía española y su estrecha relación con otros como el sector de la construcción... El mejor modelo fue aplicado a otras compañías de este sector y las malas clasificaciones fueron analizadas para justificar su utilidad por cualquier usuario potencial.

<sup>1</sup> Según el diccionario Collins un outlier o valor extremo es una persona, cosa o parte situada lejos con respecto a un grupo principal o relacionado.

## Resumen en inglés

The quality of accounting information depends on whether it has certain features or not. The most important of these features are usefulness and trustworthiness. Because of this, in the study of the behaviour of the companies in an economic sector, those companies with anomalies are known as *outliers*<sup>2</sup>. Identifying Outlier companies is often the starting point for many studies. Analysts and auditors need homogenous sets of companies with little variability to study the general behaviour of their economic sectors, and they also look for *outliers* to find accounting errors, frauds, competitive advantages...

The goal of this work is to design and use a tool to automate this outlier identification task. Neural network classifiers have been chosen to deal with this problem. The neural network is fed with a sample of companies which ratios have been previously labelled as outlier or normal. The result is a vector which the user can use to classify new non-labelled companies.

This topic was chosen for three reasons. First, fraud and bad accounting information reporting have a very negative impact in companies, markets, economy, and society. Second, Artificial Intelligence techniques like neural networks are increasingly used with similar goals such as fraud detection and bankruptcy prediction with great results. And finally, outlier detection is a proper way to identify the accounting information quality.

Once developed, the tool was applied to a set of real companies from the Spanish furniture manufacturing sector, to compare different configurations regarding missing data and degrees of detail of the output. The tool was used to look for the best model for each data configuration by trying several design parameters of the neural networks related to their complexity. In addition, several graphs and parameters were printed to show what kind of error remained for the best model.

The furniture manufacturing sector was chosen due to its importance in the Spanish economy and its close relation to several others such as the building sector... The best model was applied to other companies in this sector and bad classifications were analysed to justify its usefulness for any potential user.

<sup>2</sup> According to Collins dictionary, an outlier or extreme value is a person, a thing or part in a set, which is located far away from the related main group.

## 1. Introducción

Según el International Standard Accounting Board (IASB), en su documento de Presentación de Estados Financieros (IAS 1), “*el objetivo de propósito general de los estados financieros es el proveer de información sobre la posición financiera, el rendimiento financiero y los flujos de tesorería de una entidad que es útil a un amplio rango de usuarios en sus tomas de decisiones económicas*”. Estos estados financieros deben presentar fielmente dicha información, esto es, deben cumplir con una serie de características que se explicarán más adelante en el presente trabajo. Pero para hacerlo, las empresas que divulgan la información deben afrontar costes, que según este marco normativo deberían estar justificados por los beneficios que obtienen tanto el empresario como los *stakeholders*, y por extensión, la sociedad en su conjunto. Ahora bien, el IASB evalúa los costes y los beneficios relacionados con la publicación de la información en términos generales, no desde la perspectiva de las empresas consideradas individualmente. Esta confrontación entre coste y beneficio tiene matices importantes ya que existen incentivos para la manipulación de los resultados, cuando no responden a errores involuntarios por la escasez de recursos en su elaboración. Sin el ánimo de presentar una lista cerrada, estos incentivos pueden deberse a la necesidad de acceder a préstamos bancarios, la existencia de primas o bonos ligados a objetivos de beneficios o precios de las acciones, las expectativas de los inversores sobre resultados positivos, para reducir el perfil de riesgo de la empresa, y especialmente los incentivos fiscales. La mayor o menor aplicación de técnicas para la manipulación del resultado dependerá también de la obligación o no de realizar la auditoría financiera externa.

Otro aspecto importante en un contexto de competencia global es la creencia de que la divulgación de información afecta negativamente a la competitividad de la empresa. Las diferencias en cuanto a las exigencias de publicación de información contable según los países también producen desigualdades y perjuicios. Los empresarios perciben que están soportando un coste administrativo por suministrar información a la competencia.

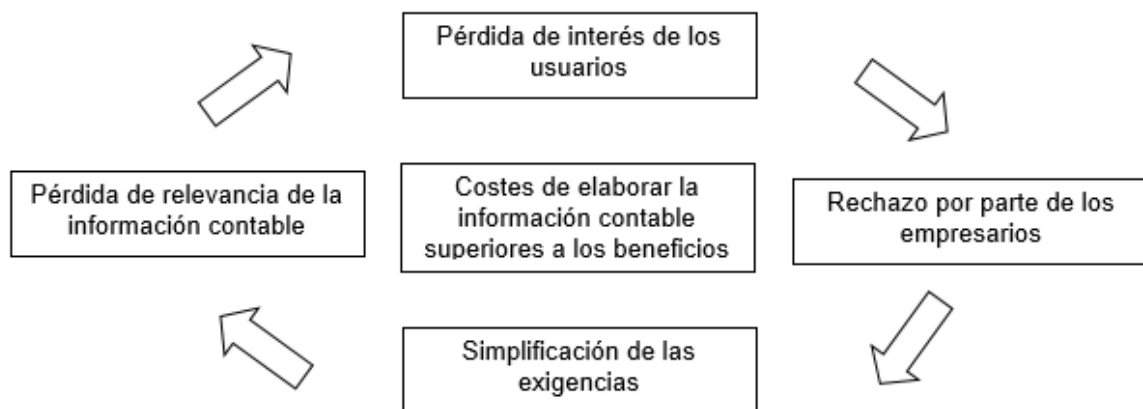
Estos desajustes entre el coste y los beneficios generan escepticismo, cuando no rechazo para el empresario, lo que ha llevado al regulador a aceptar la simplificación de la información, especialmente en empresas de reducida dimensión<sup>3</sup>, lo que redundará en una pérdida de relevancia que genera un creciente desinterés por la información (más allá de la liquidación de impuestos), que afecta a un deterioro progresivo y sostenido de su calidad (véase el Cuadro 1.1).

Las consecuencias de esta pérdida de calidad para los usuarios de dicha información contable, tanto finales (accionistas de las empresas grandes, agencias tributarias...) como directos (analistas, auditores...) produce una menor utilidad en la consecución de los que son o deberían ser sus objetivos, a pesar de las numerosas normas contables y códigos éticos que pretenden evitarlo. Un ejemplo de estos últimos es el elaborado por el IESBA (2005) y trasmite el desinterés por la realidad contable de las empresas por parte de algunos usuarios directos de la información, frente a los intereses particulares que se reflejan, por ejemplo, a través de las amenazas a la labor de los auditores englobadas en las siguientes categorías:

<sup>3</sup> E incluso en las grandes. Sirva de ejemplo que recientemente el presidente de EE.UU. ha pedido la eliminación de la publicación de resultados cuatrimestrales para las cotizadas (De la Merced y Phillips, 2018)

- De interés propio, que puede ser resultado del interés financiero u otros, por parte del contable profesional o un miembro cercano de su familia.
- De auto-revisión, que pueden ocurrir cuando un juicio previo del contable debe ser revisado por él mismo.
- De interceder por el cliente, que tienen lugar cuando un profesional defiende una posición y opinión hasta el punto de que su objetividad puede verse comprometida.
- De familiaridad, que se presentan por una relación cercana entre el profesional y los agentes que facilitan la información, resultando sensible a los intereses de estos.
- De intimidación, que aparecen cuando el profesional se ve influido en la objetividad de sus juicios por la existencia de amenazas directas o percibidas.

Cuadro 1.1. El ciclo de pérdida de relevancia de la información contable.



Fuente: Elaboración propia.

El dilema coste-beneficio de las empresas a la hora de reportar información sobre sus cuentas, junto con la subjetividad inherente a la labor de sus usuarios directos, origina la aparición de retos habitualmente reflejados por informes como el del *Center for Audit Quality (CAQ)* del AICPA (2017). Este plantea la necesidad de políticas más estrictas en las empresas a la hora de aportar información, analizando prácticas que favorecen la perpetración del fraude contable y planteando respuestas. Se menciona el especial interés de los reguladores por determinados aspectos como el reconocimiento de beneficios, gastos y valoración y depreciación de activos, centrándose abundantes recomendaciones en el primero:

- La política de reconocimiento de beneficios debe ser concreta puesto que pequeñas variaciones de interpretación pueden tener grandes impactos en el beneficio.
- Los términos de los contratos de venta deben estandarizarse en la medida de lo posible, debiéndose documentar cualquier desviación y cuando sea posible, incluir expertos contables en las negociaciones. La auditoría y controles internos de la empresa deben asegurar el cumplimiento de las políticas contables de la misma.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

- Se deben mantener líneas de comunicación y definición de responsabilidades claras entre los departamentos legal, financiero y de negocio para que todos los agentes puedan entender y aprobar las transacciones, registrándolas de forma adecuada.

Es destacable el hincapié que se realiza sobre el beneficio potencial para empresas medianas y grandes, de una mejor calidad de la información recibida por los decisores internos, por el papel en su eficacia estratégica además de la mejor satisfacción de las necesidades de los usuarios externos. Así, también se mencionan recomendaciones para la implementación de políticas contables de carácter general como:

- Políticas contables más inteligibles para “no contables”. Uso de lenguaje no técnico, utilización de ejemplos y pruebas de campo en la implantación. Se aconsejan seguimientos posteriores a su implementación que faciliten la adecuada integración de las medidas en el entorno laboral de los afectados.
- Introducción de la *compensación acompañada al cumplimiento*<sup>4</sup> vigilando que el comportamiento acorde con las políticas tenga como incentivo un impacto positivo en el desarrollo de la actividad laboral (eficiencia de esfuerzos, comodidad...).
- Necesidad de revisión periódica de las políticas y actividades de la empresa que pueden influir en la contabilidad, debiendo ser probadas antes de su implementación.

Desde una perspectiva finalista, estas circunstancias añaden complejidad a las tareas de análisis económico-financiero de los estados contables. En este tipo de análisis se juzga el desempeño de una empresa en relación con otras con las que se relaciona según criterios geográficos, de tamaño, temporales o de actividad. A las dificultades que se presuponen, se añade la existencia de fraudes o errores contables que complican la tarea de los analistas que pretenden obtener una comprensión de la realidad económica de las empresas o sectores, por la gran variabilidad en los datos de que disponen.

Cuanto mayor es la variabilidad de los resultados, más costosa es la tarea de revisión de los datos. Por ello, ***el objetivo del presente trabajo es servir los citados usuarios de la información mediante el estudio de un instrumento válido que pueda identificar las empresas cuya información contable presente valores anómalos, identificándolos, independientemente de cuál de los anteriores motivos sea el desencadenante.***

Este documento se organiza en ocho partes. En el primer apartado se justifica el interés y la utilidad del trabajo. Posteriormente se detalla el objetivo de la investigación para, a continuación, explicar la Teoría de Redes Neuronales. Después se desarrolla el caso de estudio al que se aplicará la herramienta, prosiguiendo con la explicación de las variables utilizadas. Por último, se realiza un análisis de alternativas y se exponen resultados, para terminar con las conclusiones y las limitaciones.

El siguiente apartado justifica el tema y objetivo, presentando los perjuicios que ocasiona la falsedad y la escasa calidad en el reporte de los datos contables, comparando metodologías de análisis y desarrollando el concepto de anomalía vinculado al de calidad.

<sup>4</sup> Se refiere a que la ausencia de determinadas capacidades puede suplirse con otras, por ejemplo, en una empresa pequeña el empresario compensa la falta de personal especializado y puede alcanzar niveles de cumplimiento de las normas superiores a los de una empresa más grande.



## 2. Justificación

En este trabajo se pretende demostrar la utilidad de la inteligencia artificial para complementar el trabajo humano en la clasificación de empresas en función de la calidad de su información contable. Para ello, se aplica una red neuronal cuya ventaja podría extenderse a tareas de apoyo en la labor de auditores y analistas contables.

El tema se justifica por tres motivos fundamentales. Primero, por la importancia de los perjuicios que ocasiona la falsedad o la falta de calidad de la información contable de las empresas, como los destacados por Wells (2014)<sup>5</sup> respecto a: la socavación de la fiabilidad, transparencia e integridad del proceso de la información financiera; la amenaza de la integridad y objetividad de la profesión auditora; la minoración de la confianza de los mercados de capitales y sus participantes; el perjuicio del crecimiento económico y prosperidad de una nación...

Fang, Huang y Wang (2017) distinguen entre los errores y los sesgos como características inherentes de los datos contables que pueden contraponerse. La diferencia entre ambos reside en que en los errores no hay intencionalidad, mientras que en los sesgos sí. En ocasiones, los errores reducen el interés del sesgo y limitan la relevancia de la contabilidad. Tienen consecuencias en la confianza de los mercados, favoreciendo que algunos sectores tradicionalmente reaccionen menos ante variaciones de los resultados, al ser más difícil detectar la normalidad de los datos de las empresas a partir de las variaciones en sus cotizaciones<sup>6</sup>. Según estos autores, de los 1.420 reajustes en las cuentas que se produjeron en 2006 en los EE.UU. la mayoría (el 76%) fueron debidas a pequeñas empresas corrigiendo errores.

Por todo lo anterior, las regulaciones contables y sus relaciones con las normativas fiscales también pueden alterar los incentivos de las empresas a la hora de divulgar sus datos contables por los efectos en las tasas de sesgo.

Segundo, por la inteligencia artificial como uno de los desarrollos tecnológicos que abarca la industria 4.0 (Cátedra PYME 2018), que pretende incorporar la digitalización en las empresas conectando procesos, productos, cadenas de valor y modelos de negocio, para mejorar su competitividad. La incorporación de estas técnicas en el sector estudiado no es tan abundante y entraña dificultades como la capacidad para adaptarse a las nuevas tecnologías y la disponibilidad de recursos financieros. Sin embargo, de modo indirecto se pueden aplicar a datos de carácter económico-financiero para extraer conclusiones estratégicas, que ayuden en la toma de decisiones.

Existe gran número de técnicas empleadas en diversos campos de la economía y contabilidad como el análisis de riesgo de crédito, prevención del fraude o la evaluación de retornos futuros a los inversores. Las variables y características son similares al tema de estudio, pero su ámbito es más concreto que en el último. Todos se inscriben en la teoría estadística que se ocupa del problema de la clasificación, interesada por incorporar cada observación en un único grupo de un conjunto de ellos mutuamente excluyentes. La idea es clasificar las empresas en dos grupos, uno de valores "normales" y otro de valores extremos (*outliers*).

<sup>5</sup> Citado en la tesis de Rabazo E. (2017).

<sup>6</sup> Los mercados habitualmente reaccionan menos ante cambios en los resultados de las compañías pertenecientes a sectores especialmente proclives a este ruido, regulando también el comportamiento fraudulento de sus gestores al ver estos disminuidos los potenciales beneficios que motivaron la alteración de la información.

Atiya (2001) compara las redes neuronales (NN) con otras técnicas para la predicción de quiebra, citando publicaciones como la de Salchenberger et al. (2007) que las dan ventaja frente a la Regresión Logística, con exactitudes del 91,7% frente al 83,3-85,4%, aunque existen otras como Rodríguez-López M (2014), presentan modelos de regresión lineal, logística, y análisis discriminante múltiple que las superan. Pese a todo, la conclusión de Atiya (2001) es la superioridad de las NN, lo que justifica el interés de su aplicación.

Tercero y último, el tema también se justifica por el análisis de valores anómalos que provee de una finalidad a la técnica utilizada, y simplifica la identificación de la calidad de la información contable de las empresas, a través de un abordaje estadístico. Se resume, a continuación, este problema de la detección de anomalías, identificadas con empresas de datos con menor calidad.

## 2.1. DETECCIÓN DE ANOMALÍAS (OUTLIERS)

En primer lugar, se ha de definir el concepto de anomalía:

*“Una observación que se desvía tanto de las otras observaciones como para despertar la sospecha de que fue generada por un mecanismo diferente”* (definición de Hawkins 1980, citada por Ben-Gal 2005).

*“Una anomalía es un patrón en los datos que no se ajusta al comportamiento normal esperado”* (Chandola, Banerjee y Kumar 2009)

*“Es una observación que parece desviarse marcadamente de otros miembros de la muestra en la que ocurre”* (definición de Barnett y Lewis 1994, citada por Ben-Gal 2005)

Las definiciones pueden dar pie a diferenciar los conceptos de anomalía y *outlier*, que aquí se consideran indistintamente. El proceso consistirá así, en definir una región de comportamiento normal y discriminar los ejemplos externos, aunque presenta algunos retos:

- Las observaciones en la frontera entre lo que es y no es normal.
- Las observaciones con un comportamiento malicioso pretendiendo aparentar normalidad.
- El comportamiento normal es dinámico y cambia con el tiempo en muchas situaciones.
- El grado de desviación de la normal puede ser más o menos relevante en función del área de aplicación.
- La disponibilidad de datos etiquetados suele ser un problema de por sí.
- A menudo los datos contienen ruido (fenómenos en los que no está interesado el analista), similar a las anomalías y difícil de distinguir y eliminar.

Todas estas limitaciones son señaladas por Chandola, Banerjee y Kumar (2009) para ser tenidas en cuenta en la definición del problema de detección de anomalías. Además, consideran también fundamental esclarecer:

- La naturaleza de los datos de entrada: pueden ser binarios, categóricos o continuos y cada instancia puede consistir en un atributo o varios (que a su vez pueden ser de uno sólo o varios tipos distintos). También se pueden categorizar

los datos en función de si están relacionados entre sí y cómo: espaciales (tráfico, ecosistemas...), secuenciales (climáticos...) o grafos. Hay investigación especializada en diferentes áreas de aplicación.

- El tipo de anomalías:
  - Puntuales: si un dato individual es especialmente diferente de la mayoría.
  - Contextuales o condicionales: si un dato es anómalo sólo en un contexto específico. Cada dato es definido por atributos contextuales (en datos espaciales, latitud y longitud o temporales, el momento) y comportamentales (por ejemplo, la cantidad de lluvia caída).
  - Colectivas: si una colección de datos o eventos relacionados son anómalos respecto del conjunto global. La clave es la relación de los datos entre sí.
- Los datos etiquetados: Las etiquetas serán normal o anómalo. Obtener datos etiquetados es un proceso exigente de recursos, al deberse cubrir la máxima cantidad de tipologías de comportamiento anómalo, y a menudo existe la posibilidad de que surjan eventos anómalos completamente nuevos.
- La salida del proceso: Se puede reportar una puntuación que permita ordenar los casos y seleccionar los más relevantes, o una división en categorías normal o anómalo.

Las técnicas para la detección de anomalías se pueden clasificar de muchas maneras. Una podría ser en métodos paramétricos y no paramétricos (en función de si los datos siguen una distribución estadística o no), o univariados y multivariados. Ben-Gal (2017) en cuanto a minería de datos, distingue métodos basados en distancias, de agrupación (clustering) y espaciales (gráficos o cuantitativos, en los que el objeto anómalo se halla rodeado de vecinos cuyas variables no espaciales son significativamente diferentes).

Como señala Dang (2017), frente al equilibrio entre observaciones positivas y negativas que exige un típico problema de clasificación, la detección de anomalías parte normalmente de conjuntos no balanceados que requieren ajustes. Para los métodos supervisados suele recurrirse al *oversampling* (generar nuevas muestras a partir de la clase minoritaria), *undersampling* (eliminar muestras de la clase mayoritaria) y aprendizaje sensible al coste (asigna a la muestra de la clase minoritaria mal clasificada, un coste mayor que la muestra de la clase mayoritaria mal clasificada). Los métodos no supervisados se basan en asignar una puntuación de *outlier* a cada observación, según su probabilidad de ser una anomalía.

Es necesario establecer criterios restrictivos para conseguir conjuntos más o menos homogéneos, debido a la gran dispersión de los datos contables en general y de la población observada, en particular cuando no corresponden a ninguna distribución conocida. Así, se ha optado por probar una serie de configuraciones de los datos para poder aplicar un método de clasificación basado en redes neuronales que identifique empresas anómalas.

En el próximo apartado, se explica el objetivo de la investigación y cómo se vincula la detección de anomalías explicada aquí, con la calidad de la información contable.

### 3. Objetivo de la investigación

El objetivo del trabajo es el diseño de una herramienta útil en las fases previas de diagnóstico de la calidad de la información contable para que posteriormente, analistas y auditores determinen si las empresas reflejan o no su imagen fiel a través de sus cuentas anuales. La utilidad fundamental perseguida es la reducción de la varianza de un conjunto de datos contables, según los criterios estadísticos utilizados por los analistas, que se basan en la imagen fiel (*fair value*) reflejada en la información contable. Para mejorar el rendimiento, se propone la utilización de una red neuronal que a partir de un conjunto de entrenamiento replique la revisión en conjuntos de datos más grandes.

Se pretende utilizar una metodología que automatice la labor humana de filtrado y selección de empresas anómalas con ratios contables fuera de lo esperado, independientemente de si se debe a su actividad, al reporte de información errónea, o manipulaciones de las compañías.

La efectividad de herramientas queda así puesta de manifiesto, por ejemplo, en escándalos de fraude descubiertos por firmas de investigación financiera como el de Gowex en 2014 (Placer 2017), destapado por Gotham City Research (2014). Partiendo de una cifra de ingresos extrema respecto del resto de su sector, descubrieron que el 90% de los mismos no existía, junto con otros desvíos. Longtop Financial en 2011 (Blodget, 2011), es otro caso similar descubierto por Citron Research (2011) donde el parámetro fuera de la normalidad era el margen bruto, superior al resto del sector, que explicaban por la subcontratación pero que finalmente reveló otras irregularidades.

La imagen fiel está unida al concepto de **calidad** de la información financiera y contable. Entraña la materialización de las características cualitativas de la información contable más importantes, que son la **relevancia**, consistente en la utilidad notoria, potencial o real para los fines de los destinatarios de la información (toma de decisiones), y la **fiabilidad** o capacidad de expresar con el máximo rigor las características y condiciones de los hechos reflejados.

La falta de calidad en la información contable está detrás de los fraudes que se basan en la alteración de los registros de contabilidad o documentos soporte, declaración falsa u omisiones intencionales, o la mala aplicación intencional de los principios de contabilidad. Estos tres rasgos definen en general el fraude, siendo compartidos por los distintos desarrollos del concepto de los diversos organismos reguladores como la Federación Internacional de Contadores (IFAC) y el Instituto Americano de Contadores Públicos (AICPA), el Instituto de Contabilidad y Auditoría de Cuentas (ICAC) o la Norma Técnica de Auditoría (NTA) sobre “errores e irregularidades”.

Gillette, Jarayaman y Zimmerman (2017), utilizan un modelo de regresión logística para la detección del fraude y consideran como novedad original, junto a otras ratios, que se aplique el indicador de inversión en recursos contables de las empresas, medida con la puntualidad en la entrega y los errores ortográficos de la 10-K (memoria sobre la situación financiera exigida por el SEC en base a la normativa americana). Asimismo, comparan resultados en busca del posible maquillaje intencional de las cuentas frente a errores no intencionados.

Rabazo (2017) como base de sus análisis empíricos, señala una serie de condiciones relacionadas con la posibilidad de fraude contable: activos y su crecimiento, activos blandos, fijos e intangibles, ajustes por devengo, condición financiera, deterioros de créditos comerciales, edad de la empresa, endeudamiento, estructura de propiedad, filiación sectorial, flujos de efectivo, flujos libres de efectivo, fusiones y adquisiciones,

importancia relativa de las cuentas a cobrar, impuestos, inventarios, margen operativo, pérdidas, rentabilidad económica y financiera, ventas y tamaño. El criterio que utiliza para determinar si existe fraude en las empresas analizadas, es la existencia de sentencias acusatorias sobre las empresas, referentes a la no presentación de cuentas anuales o a la presentación con errores inadmisibles para los registros mercantiles.

Para la justificación de las variables utilizadas, cita trabajos de diversos autores centrados en el efecto de las prácticas del gobierno corporativo y distintas magnitudes económico-financieras sobre la comisión de fraudes. Todos estos factores de influencia, expresados en los cuadros 3.1, 3.2, 3.3 y 3.4 pretenden también complementarse y justificar la elección del input de la herramienta diseñada en el presente trabajo. Los elegidos se desarrollan en el posterior apartado 6, “Variables del estudio” junto con sus definiciones y las asociaciones encontradas por Rabazo en cuanto a la posibilidad de fraude de las empresas.

*Cuadro 3.1. Prácticas contables que afectan a la calidad de la información contable.*

Prácticas contables que afectan a la calidad de la información reportada	
<ul style="list-style-type: none"> <li>• Reconocimiento contable del Inmovilizado Inmaterial.</li> <li>• Criterio General de Valoración del Inmovilizado Material.</li> <li>• Determinación del Coste de Producir el Inmovilizado por la Empresa.</li> <li>• Correcciones Valorativas de las Inversiones Financieras.</li> <li>• Cálculo del Coste de Producción de las Existencias.</li> <li>• Criterio Operativo de Valoración de Existencias.</li> <li>• Registro contable de un Arrendamiento Financiero.</li> <li>• Contabilización de las Devoluciones Probables de Ventas.</li> <li>• Ventas con Incertidumbre en el Cobro.</li> <li>• Reconocimiento contable de los Gastos de I+D.</li> </ul>	<ul style="list-style-type: none"> <li>• Tratamiento de las Diferencias de Cambio.</li> <li>• Reconocimiento de Ingresos en los contratos a largo plazo.</li> <li>• Reconocimiento contable de los Gastos Financieros.</li> <li>• Diferentes Criterios de Amortización de Activos.</li> <li>• Dotación de Correcciones de Valoración de Activos en Moneda.</li> <li>• Registrar los ingresos de otras compañías cuando se actúa como intermediario.</li> <li>• Capitalizar los gastos operativos, es decir, registrarlos como activos en el balance.</li> <li>• No registrar gastos o registrarlos en un periodo incorrecto.</li> <li>• Manipulación las estimaciones del valor justo del mercado.</li> <li>• Alisar los ingresos, sobreestimando los pasivos en periodos “buenos” para revertirlos cuando disminuyan los ingresos.</li> </ul>

*Fuente: Elaboración propia a partir de Rabazo, 2017.*

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

Cuadro 3.2. Causas que perjudican a la calidad de la información contable.

Causas más habituales que perjudican a la calidad de la información reportada
<ul style="list-style-type: none"><li>• Incremento del Activo.</li><li>• Incremento del Neto Patrimonial.</li><li>• Disminución del Exigible.</li><li>• Incremento del Resultado.</li><li>• Incremento de la Liquidez.</li><li>• Incremento de la Solvencia.</li><li>• Disminución del Endeudamiento.</li><li>• Incremento de la Rentabilidad.</li></ul>

Fuente: Elaboración propia a partir de Rabazo, 2017.

Cuadro 3.3. Efecto de las prácticas del gobierno corporativo en el fraude contable de las empresas.

Efecto de las prácticas del gobierno corporativo en el fraude contable de las empresas. Causan una mayor probabilidad de fraude:
<ul style="list-style-type: none"><li>• Menor cantidad de consejeros externos (no dependientes laboral o económicamente) frente a consejeros gestores, en el Consejo, Comité de Auditoría y Comité de Compensación.</li><li>• Menor posesión de acciones de la empresa por los consejeros externos.</li><li>• Mayor número de puestos en otros consejos, ocupados por los consejeros externos.</li><li>• Mayor tamaño de los consejos frente a otras empresas.</li><li>• Menor salario de los ejecutivos.</li><li>• Mayor porcentaje de la compensación basada en acciones de los ejecutivos, frente a la total.</li><li>• Mayor sensibilidad al cambio del valor de las acciones de la empresa.</li><li>• Mayor concentración del poder estructural de la empresa.</li><li>• Corta permanencia de los miembros del consejo accionarial y el equipo directivo.</li><li>• Coincidencia del CEO y el presidente del Consejo en la misma persona.</li><li>• Empresas no auditadas por un Big 4.</li><li>• Relación más corta con la empresa auditora.</li><li>• Mayor crecimiento en los años recientes (posiblemente para aparentar estabilidad).</li><li>• Aumento del porcentaje de propiedad superior al 5% mantenido por los gerentes.</li><li>• Mayores perspectivas de crecimiento por parte del mercado.</li><li>• Participación en fusiones y adquisiciones.</li><li>• Carencia de formación financiera de los consejeros.</li><li>• Agencia del gobierno como accionista mayoritario.</li><li>• Haber realizado una emisión de acciones recientemente.</li></ul>

Fuente: Elaboración propia a partir de Rabazo, 2017.

Cuadro 3.4. Efecto de ratios y magnitudes económico-financieras en el fraude contable de las empresas.

Efecto de ratios y magnitudes económico-financieras en el fraude contable de las empresas. Causan una mayor probabilidad de fraude:
<ul style="list-style-type: none"><li>• Mayor apalancamiento.</li><li>• Mayor activo corriente, inventarios y cuentas a cobrar.</li><li>• Menor liquidez.</li><li>• Mala condición financiera.</li><li>• Mayores ventas en el periodo previo al suceso.</li><li>• Grandes devengos positivos hasta el año del fraude.</li><li>• Mayor endeudamiento.</li><li>• Significativa actividad de venta de acciones.</li><li>• Menor rentabilidad (aunque hay opiniones enfrentadas según el autor).</li><li>• Resultados contables significativamente mayores a los cash flow.</li><li>• Mayor tamaño (aunque hay opiniones enfrentadas según el autor).</li><li>• Mayor cantidad de sectores en los que la empresa opera.</li><li>• Pago de dividendos con menor frecuencia.</li><li>• Mayor pago de dividendos el año anterior al fraude.</li><li>• Mayores ingresos inesperados por empleado.</li><li>• Menor ratio "book to market" (valor contable frente a valor de mercado).</li><li>• En el año del fraude, para firmas con resultado positivo antes de impuestos, mayores niveles de gastos por impuestos diferidos.</li></ul>

Fuente: Elaboración propia a partir de Rabazo, 2017.

El concepto de calidad de la información, más general que el de fraude o la quiebra, se ha considerado más útil para sus usuarios al permitir una mayor libertad y rango de aplicaciones posterior. El instrumento desarrollado en el seno de este trabajo debería señalar, además de fraudes, de desviaciones de los datos habituales del sector derivadas de la adopción de estrategias originales con especial influencia en algunas ratios, favorecedoras de ventajas competitivas o situaciones comprometidas para sus decisores.

El Cuadro 3.5 resume las cualidades de la información contable, extraídas de "Análisis de estados contables: Comentarios y ejercicios" de Martínez y Somohano (2002), aunque algunas han cambiado desde entonces. Tal y como mencionan estos autores, los documentos originales actualizados de los **marcos conceptuales** más relevantes por el ámbito nacional del estudio, que son el del SFAC 2 (Statements of Financial Accounting Concepts No 2), el del IASB (The International Accounting Standards Board) y el de la AECA (Asociación Española de Contabilidad y Administración de Empresas), contrastan la importancia de la relevancia y fiabilidad en relación con la calidad, variando entre los distintos marcos tan sólo el grado de concreción en cuanto a las características que las respaldan o complementan. Así, se establece en todos que la información no puede dejar de ser relevante y fiable si ha de ser útil, si bien para ganar en una de las dos características, es a menudo necesario sacrificar parte de la otra. La calidad, además, se encuentra vinculada estrechamente con la utilidad de dicha información para la toma de decisiones.

En "The Conceptual Framework for Financial Reporting" el IASB menciona los valores confirmatorio y predictivo de la información como componentes de su relevancia. Además, se hace referencia al concepto de materialidad, estrechamente relacionado con el descrito como calidad de la información, al constituir la propiedad que se da, cuando la ausencia o malinterpretación de la información puede influenciar las



## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

decisiones sobre la entidad que representa. También se mencionan la completitud, neutralidad y ausencia de errores como pilares de la fiabilidad. Por otro lado, la comparabilidad, verificabilidad, oportunidad y comprensibilidad son señaladas de forma global e independiente como cualidades que refuerzan la utilidad de la información que ya es relevante y fiable. Asimismo, se hace referencia al coste como una restricción en el reporte de la información financiera, de importancia al valorar el beneficio que supone la mejora de cualquiera de sus cualidades.

La principal dificultad del problema de clasificación reside en el carácter cualitativo de la definición de calidad que será cuantificado a través de la medida de la variabilidad de las magnitudes contables, una medida también relativa. Esta aproximación estadística origina errores con empresas fraudulentas consideradas como normales por valores habituales de sus ratios respecto al resto del sector, y empresas normales señaladas como de menor calidad de información, por una estrategia y estado de madurez lejos del resto del sector.

*Cuadro 3.5. Características cualitativas de la información contable según distintos marcos conceptuales.*

Características cualitativas	1	2	3	4	5	6	7	8	9	10	11
<i>Materialidad o importancia relativa</i>		X		X		X	X	X	X	X	X
<b>Relevancia</b>	X	X	X	X	X	X	X	X	X	X	X
Totalidad, integridad o revelación completa	X		X	X		X	X	X			X
Identificabilidad								X			
Claridad	X	X	X	X		X		X			
Comparabilidad	X	X	X		X	X	X	X	X	X	X
Sustancia sobre la forma		X		X			X	X			X
<b>Fiabilidad o veracidad</b>				X		X	X	X	X	X	X
Imparcialidad, neutralidad o insesgabilidad	X	X		X	X	X	X	X			
Objetividad	X							X		X	
Verificabilidad	X			X	X	X		X		X	
Representación fiel					X	X	X	X		X	X
Prudencia o conservadurismo				X		X	X	X		X	X
<i>Oportunidad</i>	X		X	X		X	X	X	X	X	X
<i>Razonabilidad</i>		X						X			
<i>Economicidad o coste-beneficio</i>				X		X	X	X	X	X	X
Uniformidad o continuidad		X		X	X	X					
Confianza			X								
Precisión				X							
Racionalidad				X		X					
Flexibilidad				X							
Cuantificación					X					X	
Valor predictivo						X				X	
Valor de confirmación						X				X	
Comprensibilidad							X		X	X	X

1) APB núm. 4. 2) Informe Trueblood. 3) Corporate Report. 4) Stamp Report. 5) AAA (A Statement of Basic Accounting Theory-ASOBAT). 6) SFAC 2. 7) IASC. 8) AECA (marco conceptual). 9) Australian Accounting Research Foundation-AARF. 10) Canadian Institute of Chartered Accountants (CICA). 11) Accounting Standard Board-ASB (UK).

*Fuente: Martínez y Somohano (2002).*

La variabilidad indicativa de la calidad y utilidad de los datos será analizada por un proceso de identificación sistemática de *outliers* mediante un método de clasificación por redes neuronales, explicado en detalle en el siguiente apartado.




## 4. Teoría de Redes Neuronales

### 4.1. CONCEPTO Y DESCRIPCIÓN

El contexto de aplicación es la clasificación supervisada. La red neuronal se entrena con empresas cuyas ratios fueron juzgadas de antemano como *outliers* o normales, resultando un vector de pesos, el modelo, que puede clasificar empresas distintas. El algoritmo está formado por unidades o neuronas con pesos asociados a cada unidad, agrupadas en capas de entrada, salida y una o varias ocultas intermedias (Gráfico 4.1).

Gráfica 4.1. Esquema de capas de red neuronal.



Fuente: Ng 2017

La implementación parte de una “*feed-forward network*”, función que la red ejecutará para clasificar los casos. Consiste en estas iteraciones:

1. Combinación lineal de los valores de la capa anterior más un error, con el vector de pesos como coeficientes (Cuadro 4.2).
2. Aplicación de cada resultado a una función de activación que tiene como salida un número entre 0 y 1, como la sigmoide utilizada aquí (Cuadro 4.2)
3. Repetición del proceso hasta la capa final donde, si lo que se pretende es una clasificación pura, se definirá un umbral para obtener 0 ó 1 en cada unidad de salida.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

*Operaciones realizadas por la Feed-Forward Network y función sigmoide.*

$$\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$$

$$a^{(1)} = x$$

$$z^{(2)} = \Theta^{(1)} a^{(1)}$$

$$a^{(2)} = g(z^{(2)}) \quad (\text{add } a_0^{(2)})$$

$$z^{(3)} = \Theta^{(2)} a^{(2)}$$

$$a^{(3)} = g(z^{(3)}) \quad (\text{add } a_0^{(3)})$$

$$z^{(4)} = \Theta^{(3)} a^{(3)}$$

$$a^{(4)} = h_{\Theta}(x) = g(z^{(4)})$$

$$g(z) = \frac{1}{1 + e^{-z}}$$

*Nota. El ejemplo considera una red de 4 capas, con un conjunto de entrenamiento de m elementos y una variable. El superíndice es el número de capa, los  $\theta$  son los pesos para cada capa y g es la función sigmoide.*

(Ng 2017)

Para el entrenamiento, el vector de pesos se inicializa aleatoriamente y se ejecuta el “feed-forward”. Después el “backpropagation”, a partir de la diferencia entre la salida del anterior y la clasificación manual previa, realiza operaciones en pasos de sentido contrario (desde la última capa hasta la primera), hasta obtener el gradiente (Cuadro 4.3), que será utilizado por el algoritmo de optimización para minimizar la función de coste y conseguir el modelo.

*Obtención del Gradiente mediante el “backpropagation” y función de coste.*

$$\delta_j^{(4)} = a_j^{(4)} - y_j$$

$$\delta^{(3)} = (\Theta^{(3)})^T \delta^{(4)} \cdot * g'(z^{(3)})$$

$$\delta^{(2)} = (\Theta^{(2)})^T \delta^{(3)} \cdot * g'(z^{(2)})$$

*Nota: Se hace iterativamente, para cada capa, lo siguiente:*

$$\text{Set } \Delta_{ij}^{(l)} = 0 \quad (\text{for all } l, i, j).$$

$$\Delta_{ij}^{(l)} := \Delta_{ij}^{(l)} + a_j^{(l)} \delta_i^{(l+1)}$$

$$D_{ij}^{(l)} := \frac{1}{m} \Delta_{ij}^{(l)} + \lambda \Theta_{ij}^{(l)} \quad \text{if } j \neq 0$$

$$D_{ij}^{(l)} := \frac{1}{m} \Delta_{ij}^{(l)} \quad \text{if } j = 0$$

$$\frac{\partial}{\partial \Theta_{ij}^{(l)}} J(\Theta) = D_{ij}^{(l)}$$

*Nota: El conjunto de las  $D_{ij}$  es el gradiente.*

La función de coste es la siguiente:

$$h_{\Theta}(x) \in \mathbb{R}^K \quad (h_{\Theta}(x))_i = i^{th} \text{ output}$$

$$J(\Theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{k=1}^K y_k^{(i)} \log(h_{\Theta}(x^{(i)}))_k + (1 - y_k^{(i)}) \log(1 - (h_{\Theta}(x^{(i)}))_k) \right]$$

$$+ \frac{\lambda}{2m} \sum_{l=1}^{L-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (\Theta_{ji}^{(l)})^2$$

Nota: Los índices  $i$  representan a los casos, los  $j$  representan a las variables,  $s$  es el número de unidades por capa,  $L$  es el número de capas,  $K$  el número de unidades de salida y  $h$  el modelo.

(Ng 2017)

En el siguiente apartado se desarrollan los errores de clasificación y métodos de evaluación de modelos utilizados.

Tabla 4.1. Ventajas y desventajas de las redes neuronales como método.

Ventajas	Desventajas
Universalidad de la función de aproximación. Cualquier dependencia funcional. Pueden ser no lineales (la regresión lineal y logística son casos particulares).	Es preciso conocer bien el problema.
Trabajan con gran cantidad de variables y datos.	El efecto caja negra, no se revela normalmente la naturaleza de las relaciones entre variables.
Son explicativos.	Requieren la definición de muchos parámetros.
Autoorganización y Aprendizaje adaptativo: disponen de capacidad de aprendizaje automática. Menos trabajo personal que con otros métodos.	Los procesos son muy largos.
Las entradas se incorporan directamente sin interpretación o modificación previos.	
Resistencia a cierta falta de fiabilidad de datos.	
Posibilidades de la variable de predicción, clasificación.	
Aplicación a la segmentación, determinan por sí mismas cuantos clústeres encierran cada clase.	
Facilidad de análisis y modelización de las relaciones espaciales, geoográficas, etc.	
Modelo continuo y derivable de cara a la visualización, y aplicaciones prácticas.	


Fuente: Ricote 2006.

## 4.2. APLICACIÓN DE LAS REDES NEURONALES

Una medida del rendimiento del modelo es el valor de su función de coste, que en función del conjunto al que se aplique, se denomina error de entrenamiento, validación o prueba.

Los dos últimos se denominan error de generalización, refiriéndose a datos distintos de los de entrenamiento y sirven para elegir el mejor diseño (número de capas ocultas, unidades por capa y lambda) y configuración de datos (métodos, variables...). Según Dang (2017) este último se descompone en sesgo, desviación entre el valor esperado del resultado del algoritmo de aprendizaje y el real; varianza, variación en la capacidad de aprendizaje debida al conjunto de entrenamiento; y ruido intrínseco de los datos, o dificultad de la tarea de aprendizaje. Si la excesiva complejidad del algoritmo o las variables limitan el aprendizaje, predomina el sesgo, apareciendo el “*underfitting*”. Si son necesarios más casos de entrenamiento, predomina la varianza y aparece el “*overfitting*”. Para identificarlos se seguirá el consejo de Ng (2017), utilizándose las siguientes salidas gráficas e indicadores.

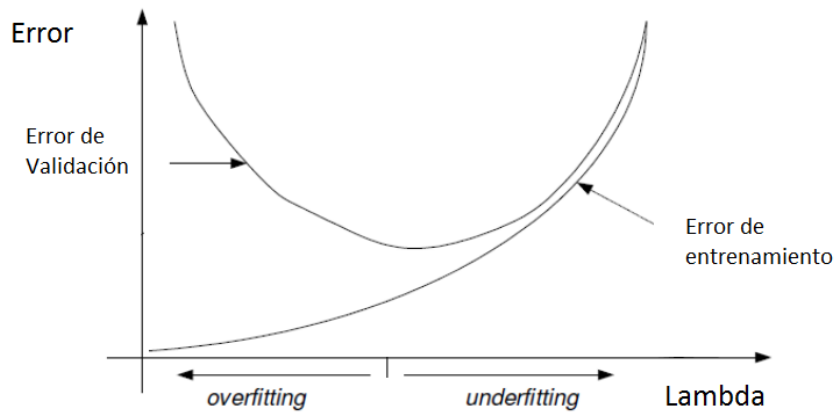
Gráfica 4.1. Descomposición del error de generalización.



Fuente: Dang 2017.

La principal aliada contra el “*overfitting*” es la regularización, consistente en añadir a la función de coste el parámetro *lambda*, que penaliza la influencia de variables en excesiva cantidad o complejidad. Los valores excesivamente grandes también pueden producir “*underfitting*”, presentando el comportamiento teórico de la Gráfica 4.6. Se ha buscado aquí el modelo con el mínimo error de validación posible, probando valores entre 0 y 10.


Gráfico 4.2. Error (valor de la función de coste) frente al valor del parámetro lambda utilizado.



Fuente: Elaboración propia a partir de Ng 2017.

Además, para cada diseño se han probado distintos tamaños y números de capas ocultas, imprimiéndose la evolución del coste en los conjuntos de entrenamiento y validación, frente a la complejidad de la red (Gráfica 4.7).

Gráfica 4.3. Error (valor de la función de coste) frente a la complejidad (número de capas ocultas o de elementos en cada capa oculta).

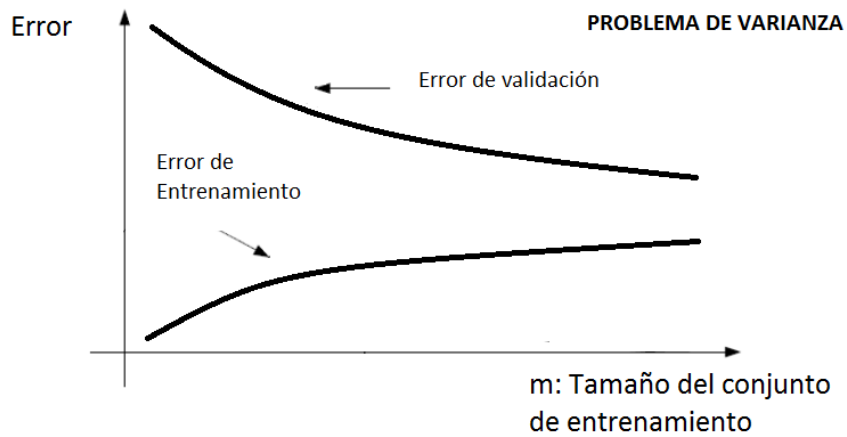


Fuente: Elaboración propia a partir de Ng 2017.

Por último, la **curva de aprendizaje** representa los costes de entrenamiento y validación correspondientes a modelos entrenados con conjuntos de entrenamiento de tamaño creciente, de entre un caso y el conjunto de entrenamiento completo. Los problemas de sesgo aparecen cuando los costes convergen con más casos de entrenamiento, y los de varianza, cuando existe apreciable distancia entre los errores de entrenamiento y validación incluso para los modelos de más casos de entrenamiento.

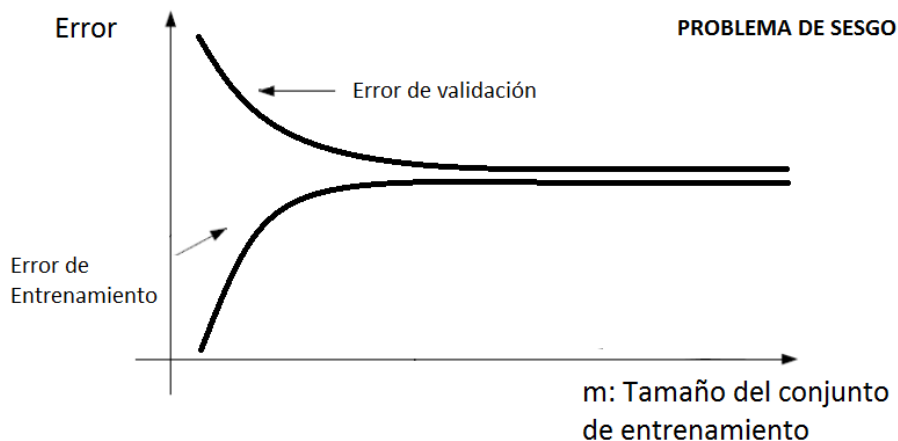
## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

Gráfica 4.4. Curva de aprendizaje de referencia, de un modelo con problemas de varianza.



Fuente: Elaboración propia a partir de Ng 2017.

Gráfica 4.5. Curva de aprendizaje de referencia, de un modelo con problemas de sesgo.



Fuente: Elaboración propia a partir de Ng 2017.

Los indicadores del Cuadro 4.10 son interesantes por su mayor carácter intuitivo frente al valor de la función de coste y se derivan del número de errores tipo I y II en el conjunto de prueba. F1, el que más utilizaremos, representa el desempeño global independiente del tipo de error. En los apartados siguientes, se contextualizarán los datos a los que se aplicará la herramienta y se detallarán las variables de entrada para los modelos.

Cuadro 4.2. "Accuracy", "Precision", "Recall" y "F1".

		Realidad	
		1	0
Modelo	1	Verdadero positivo	Falso positivo
	0	Falso negativo	Verdadero negativo

$$Accuracy = \frac{VerdaderosPositivos + VerdaderosNegativos}{Total}$$

$$Precision = \frac{VerdaderosPositivos}{VerdaderosPositivos + FalsosPositivos}$$

$$Recall = \frac{VerdaderosPositivos}{VerdaderosPositivos + FalsosNegativos}$$

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Fuente: Elaboración propia a partir de Ng 2017.

## 5. Aplicación a un caso de estudio: el sector de fabricación de muebles en España

Se ha utilizado la información contenida en las cuentas anuales no consolidadas (individuales) de las empresas de actividad con código “31: Fabricación de Muebles” (CNAE 2009), sector importante no sólo por su propia actividad, sino también por su relación con otros como la construcción, la decoración, etc. Tradicionalmente ha sido importante en la economía española en la que prevalece la pequeña y mediana empresa. Se trata de un sector intensivo en mano de obra, con un promedio de 27 trabajadores por empresa. Mayoritariamente presentan sus cuentas anuales sin informe de auditoría y con sistemas contables cuya calidad del resultado depende del buen hacer de las asesorías y gestorías. Por tanto, es un sector representativo de otros que siguen las mismas pautas a la hora de cumplir las obligaciones de información.

La población está constituida por 2.653 empresas cuya información está disponible en la base de datos SABI de Informa, que facturan más de cien mil euros anuales y están activas. Esta población coincide con la del informe “El sector de fabricación de muebles en España. Situación para la Industria 4.0” (Cátedra PYME 2017), en el que se analiza detalladamente, proporcionando una importante información de partida, resumida brevemente en los siguientes párrafos, en cuanto a características y evolución de las empresas analizadas.

La antigüedad media de las empresas es de 16,6 años. Si se segmenta por tamaño y antigüedad las empresas que integran la población, se obtiene el resultado de la Tabla 5.1. Se observa que la mayoría (70,6%) tiene más de 10 años y el 87% factura menos de 2 millones de euros, contando el 85,3% de éstas últimas con más de 5 años. Esto sugiere que el 29,5% del total de la población son empresas de menos de 10 años que surgen ante el cierre de otras más grandes. Se puede comprobar que estos datos se aproximan a los de la muestra de 809 empresas, de la Tabla 5.2.

Tabla 5.1. Segmentación por tamaño y antigüedad las empresas de la población.

Tamaño según facturación en 2014					
Edad	<2 MM €	2-10 MM €	10-50 MM €	>50 MM €	Total
<= 5 años	14,7%	0,8%	0,1%	0,0%	15,5%
>5-10 años	12,9%	0,8%	0,1%	0,0%	14,0%
>10-20 años	33,8%	3,5%	0,3%	0,1%	37,8%
>20 años	25,7%	5,8%	1,1%	0,1%	32,8%
<b>Total</b>	<b>87,0%</b>	<b>11,1%</b>	<b>1,8%</b>	<b>0,3%</b>	<b>100,0%</b>

Fuente: Elaboración propia a partir de Cátedra PYME 2018.

Tabla 5.2. Segmentación por tamaño y antigüedad las empresas de la muestra de 809 empresas.

Edad	<2 MM €	2-10 MM €	10-50 MM €	>50 MM €	Total
<= 5 años	7,4%	1,5%	0,5%	0,1%	9,5%
>5-10 años	9,2%	1,9%	0,6%	0,1%	11,9%
>10-20 años	31,7%	6,6%	2,1%	0,4%	40,7%
>20 años	29,6%	6,1%	1,9%	0,3%	37,9%
<b>Total</b>	<b>77,9%</b>	<b>16,2%</b>	<b>5,1%</b>	<b>0,9%</b>	<b>100,0%</b>

Fuente: Elaboración propia a partir de Cátedra PYME 2018.



En cuanto a la segmentación por subactividad de la población (Tabla 5.3), se puede señalar que “Fabricación de otros muebles” cuenta con el 73% de las empresas, subiendo al 90% si se considera junto con “Fabricación de muebles de cocina”. Según la revisión de PYME, muchas empresas de la primera subactividad deberían estar clasificadas en otros epígrafes como comercialización de muebles o realización de proyectos-contract. El habitual acompañamiento de obras hace habituales las ofertas de mobiliario para baños, reformas generales del hogar (muebles empotrados...) y proyectos-contract.

Para el caso de los muebles de cocina, predominan las compañías dedicadas a la fabricación e instalación junto con electrodomésticos. Esta subactividad y los fabricantes de componentes de muebles integran las empresas más pequeñas cuyos ingresos medios entre 2007 y 2014, según la muestra de PYME (Tabla 5.4), cayeron en torno al 36%, acompañados de los gastos de personal, que hacen que en 2014 el 64% de las empresas de la muestra hayan sufrido pérdidas mayores que sus fondos propios de 2005, siendo la rentabilidad económica media negativa.

Tabla 5.3. Segmentación por subactividad de la población.

Nace 2009	Actividad primaria	Cantidad	%
3101	Fabricación de muebles de oficina y de establecimientos comerciales	197	7%
3102	Fabricación de muebles de cocina	438	17%
3103	Fabricación de colchones	89	3%
3109	Fabricación de otros muebles	1.929	73%
		2693	100%

Fuente: Elaboración propia a partir de Cátedra PYME 2018.

Tabla 5.4. Segmentación por subactividad de la muestra.

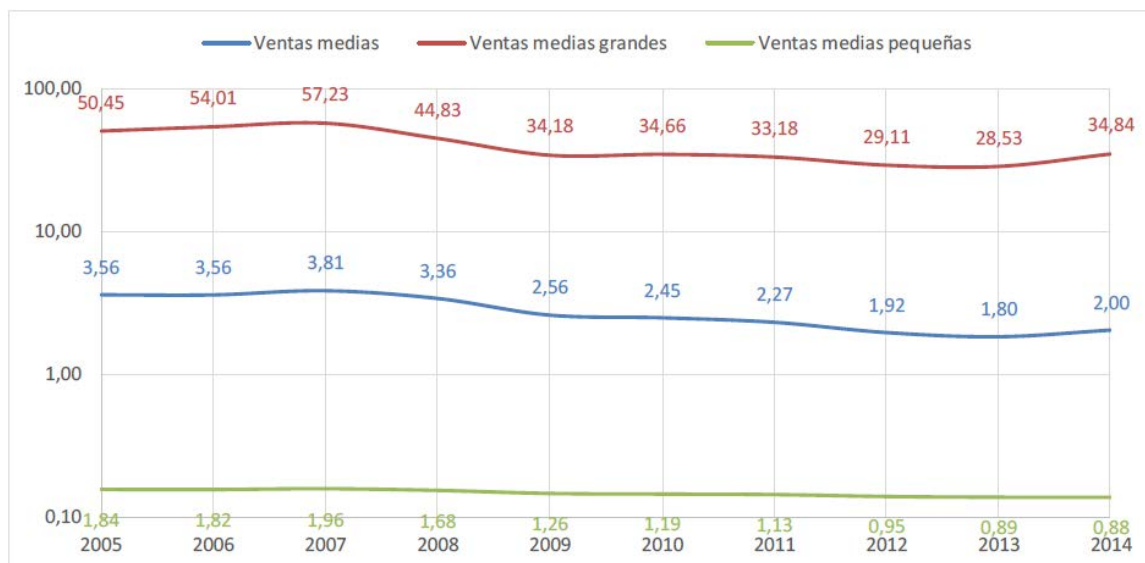
Nace 2009	Actividad primaria	Cantidad	%
3101	Fabricación de muebles de oficina y de establecimientos comerciales	57	11%
3102	Fabricación de muebles de cocina	97	18%
3103	Fabricación de colchones	33	6%
3109	Fabricación de otros muebles	352	65%
		539	100%

Fuente: Elaboración propia a partir de Cátedra PYME 2018.

Otra información de interés sobre la población es la evolución de los ingresos medios, que sufren un descenso del 30,87% para las empresas grandes-medianas entre 2005 y 2014, mientras que para las pequeñas caen un 52,17%, coincidiendo con la crisis financiera global de dicho periodo (Gráfica 5.5). Esta evolución se desarrolla en el apartado siguiente junto con las características más reseñables del sector, señalándose la influencia de dicha crisis y las situaciones que presentan las compañías ante la misma.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

Gráfica 5.1. Ventas medias del sector del mueble en España.



Fuente: Cátedra PYME 2018.

### *El Sector de Fabricación de Muebles (CNAE 31) y los efectos de la crisis de 2007*

Es destacable la evolución creciente de la cifra de negocios hasta 2007, acompañando al sector industrial en general. Con la crisis cae hasta llegar en 2013 a valores similares a 1993. La crisis del sector de la construcción obliga a la revisión de las estrategias para competir, apuntando hacia la innovación y diferenciación, con la necesidad de una buena imagen de marca.

En nuestro país, el sector se encuentra en un estadio maduro, con una tendencia a la especialización que limita las capacidades de adaptación a los cambios. Además, el sector se encuentra fuertemente influenciado por los precios de la madera incluso para algunos mercados de gama media y alta. Esto, unido al desaprovechamiento de la expansión anterior al 2007 y acompañado a cambios en los hábitos de compra relacionados con las nuevas tecnologías, han acrecentado los efectos negativos de la presión de las importaciones desde China y Estados Unidos, y de las grandes cadenas de distribución.

La crisis ha originado la desaparición de la mitad de las empresas, constituyendo un gran número de las empresas jóvenes, consecuencia del cierre de otras más grandes (el 70% del total con más de 10 años). Ante la crisis se definen cuatro tipos de compañías: las que crecen en ventas y se mantienen, las que tenían la suficiente solvencia para soportar la crisis sin recurrir a financiación externa, las que aumentan el endeudamiento ante la reducción de ventas y las que quiebran por insuficiente financiación.

Los efectos de la crisis sobre la contabilidad pasan por la reducción de ventas que influye en las inversiones de inmovilizado asociadas a la rigidez de ciertos costes, a su vez vinculados a la menor disponibilidad de tesorería que empeora los indicadores del endeudamiento, principal salida de dicho problema. Este fenómeno se explica a continuación, en términos de indicadores contables como los desarrollados en el

siguiente apartado, siendo muchos, input de la herramienta eje del trabajo por su importancia en el estudio del comportamiento del sector.

En cuanto al Cash Flow Libre se observa un mejor comportamiento de las empresas medianas y grandes frente a las pequeñas. Sin embargo, muchas de las primeras que realizaron inversiones a largo plazo en el inicio de la crisis, tienen una pérdida progresiva de capital corriente durante esta que las obliga a enajenar inmovilizados, mientras que las pequeñas mantienen estable su solvencia durante un tiempo a pesar del peor comportamiento en Cash Flow, por sus existencias y deudores (reflejados en sus periodos medios de almacén y de cobro).

En cuanto al resultado se definen dos fases. La primera es de menor magnitud, hasta 2009. La reducción del valor de los materiales utilizados permite un mantenimiento de la productividad y el personal en nómina hasta 2010, cuando los gastos de personal comienzan a reducirse en la misma medida que las ventas. Esto parece facilitado por una reducción del consumo en las empresas pequeñas y una reducción en los precios de compra a los proveedores en las grandes y medianas.

La segunda oleada de la crisis, además de enfrentarse a través de las desinversiones y aumento de las existencias para mantener la solvencia, también se encara mediante el endeudamiento. En 2007, 2009 y 2013 la disminución del Cash Flow Libre lleva a recurrir a la deuda a largo plazo, renegociando la de corto. Sin embargo, las empresas medianas y grandes son las que aumentan más la deuda frente a las pequeñas que la mantienen o reducen. A partir de 2011 destacan las aportaciones de capital por los accionistas para compensar la caída del patrimonio neto, frente a las retiradas de fondos o repartos de beneficios de 2008, con el cambio de tendencia.

La disminución de las ventas que redujo las rotaciones, y la caída de beneficio y margen, han llevado a la rentabilidad económica a valores negativos a partir de 2010. Las grandes compañías mantienen resultados positivos a pesar de la reducción de las ventas y activos de 2008, pudiendo mantener las rotaciones y el aumento de la deuda a tipos de interés bajo, que permitieron cierta estabilidad en la rentabilidad financiera. Sin embargo, las pequeñas presentan pérdidas desde 2009, recurriendo más a recursos propios, aunque no aumentaron en exceso su endeudamiento, pese a que el coste de la deuda sea mayor que el de las anteriores.

### *Objetivo del estudio empírico*

A nivel metodológico, el objetivo del estudio se resume en la elaboración de un modelo de clasificación supervisado para la detección de anomalías, correspondientes a la categoría 1, frente a la 0. El conjunto de entrenamiento ha sido etiquetado de forma que la varianza de las restantes empresas si se prescinde de cada *outlier* identificado, se vea reducida hasta un determinado umbral para cada variable, establecido como un determinado número de veces la media.

El tamaño de la muestra del sector, cuyas características y evolución durante el periodo de estudio se ha resumido anteriormente, asciende a 809 empresas. También se ha utilizado otra muestra de 536 casos que excluye las empresas con anualidades sin datos. Así, la muestra de 809 proporciona un error máximo del 2.87% en la estimación de una proporción con un nivel de confianza del 95% ( $p=q=0,5$ ), mientras que para la de 536 empresas es del 3.78% para el mismo nivel de confianza.

La elección de un sector concreto pretende reducir el efecto de la mayor variabilidad en los datos que supondría un análisis multisectorial, teniendo en cuenta que ya una sola actividad, de por sí engloba varias subactividades con sus propias particularidades.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

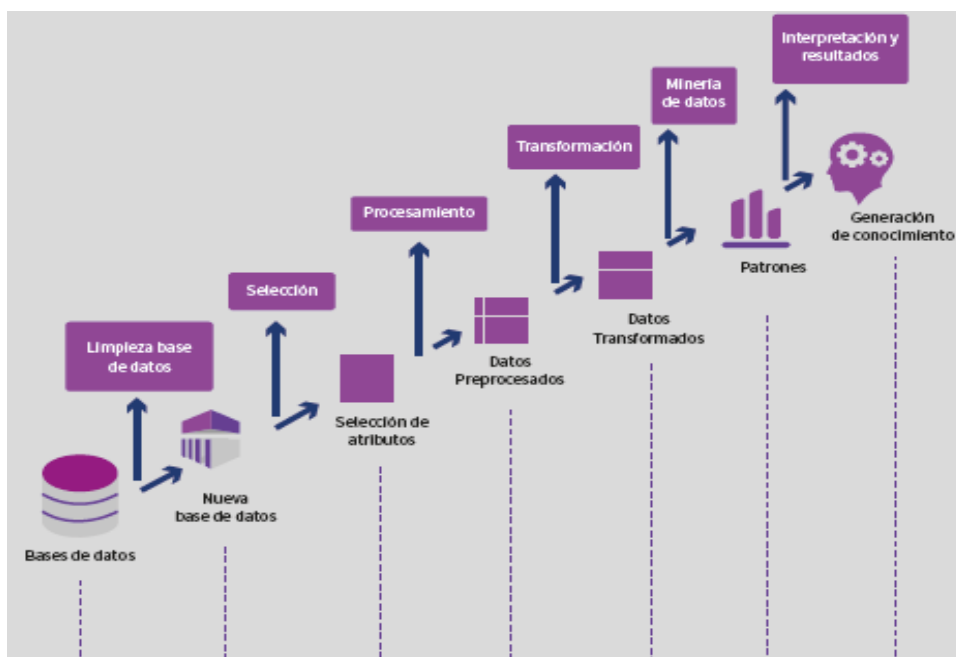
La detección de anomalías mediante herramientas como la aquí estudiada, puede considerarse como una etapa del trabajo de analistas y auditores, en un proceso de generación de conocimiento a partir de información de bases de datos (*Knowledge Discovery in Data Bases, KDD*), tal y como el que resume la Gráfica 5.6.

Sin embargo, la ejecución del propio proceso de detección de anomalías también puede considerarse como un proceso de KDD. Se plantea una primera fase de **exploración y limpieza**, con análisis descriptivos y exploratorios con el objeto de determinar correlaciones y dependencia entre variables, visualizarlas para identificar su distribución, características básicas y en ocasiones se aplican métodos de agrupamiento y segmentación. A este respecto, aunque partimos de una base de datos ya depurada, en este trabajo se ha realizado el análisis presente al comienzo de este apartado.

También se aplica a menudo una fase de **reducción de variables** para identificar las más significativas, mejorar la velocidad de procesado si es un modelo predictivo... Para tener una primera idea de la influencia de las variables entre sí en la clasificación final de las empresas, se ha optado por introducir en el Anexo I una matriz de correlaciones. A partir de sus valores se puede deducir, por ejemplo, que la eliminación del desglose de la ratio endeudamiento en un valor general y otros dos referidos al corto y al largo plazo, aporta menos información que la variedad de indicadores de la solvencia a corto plazo de las entidades (solvencia, prueba ácida y liquidez). Aunque esto nos podría ayudar en una primera etapa, de forma complementaria a otros métodos como el análisis de componentes principales, se han preferido utilizar todas las ratios citadas en el siguiente apartado por la tolerancia de las redes neuronales en cuanto a la cantidad de variables de entrada.

Asimismo, es a menudo necesaria la **transformación** (normalización, escalado...) en función de la técnica elegida. Para nuestro caso, se limita del cálculo de las ratios financieras, por su carácter más comparable, informativo y útil que el de los datos contables en bruto.

Cuadro 5.1. Fases de los procesos de KDD.



Fuente: Unidad de Información y Análisis Financiero (UIAF) (2014).

Todos estos pasos culminan en la etapa de minería de datos, en la que se pretende aplicar las metodologías para identificar patrones en los datos, que pueden ser **descriptivas o predictivas** en función de su finalidad, así como **supervisadas, semi-supervisadas o no supervisadas**, si es necesario alimentarlas con un conjunto de entrenamiento para que cumplan su objetivo, si el conjunto de entrenamiento puede incluir un conjunto de elementos no etiquetados, o si no es necesario dicho conjunto, respectivamente. En función de la aplicación, según la misma fuente, se pueden distinguir cinco tipologías distintas de técnicas: **Identificación, Clasificación, Agrupación, Asociación y Predicción**. No se explorarán en más detalle dado que a menudo, una misma técnica puede tener varias de las aplicaciones, como es el propio caso de las redes neuronales, eje del presente estudio como método de clasificación supervisado pero susceptibles de ser aplicadas de otras formas.

La aplicación iterativa del proceso de generación de conocimiento permite depurar en cada ciclo las decisiones tomadas. Esto afecta a los parámetros de los métodos o las variables utilizadas, hasta conseguir conclusiones y modelos útiles que han de diferenciar empresas con información contable de calidad o utilidad, frente a otras que no lo son. A continuación, se desarrollan las variables elegidas como entrada del proceso, que caracterizan a las empresas con el fin de poder determinar si se tratan de casos anómalos o no.

## 6. Variables del estudio

Las siguientes ratios financieras que se utilizan habitualmente en los análisis de datos contables, son utilizadas aquí como variables independientes. En concreto, se utilizan como referencia las mencionadas en las asociaciones y causas del fraude de Rabazo (2017) y son también compartidas por la bibliografía sobre modelos de quiebra citada con anterioridad.

### *Periodos Medios*

En primer lugar, se han considerado importantes los periodos medios a la hora de evaluar la información proporcionada por las empresas. En el sector de estudio estas siguen el comportamiento habitual de las actividades industriales con ciclos más amplios que las comerciales, habiéndose preferido condensar los periodos de almacenamiento en uno sólo por esta particularidad que permite simplificar el problema sin perjudicar los resultados.

Tabla 6.1. *Periodos Medios.*

Ratio	Fórmula
Periodo Medio de Almacenamiento	$PMA = \frac{365}{\frac{\text{Aprovisionamientos}}{\left(\frac{\text{Existencias Finales} + \text{Existencias Iniciales}}{2}\right)}}$
Periodo Medio de Cobro	$PMC = \frac{365}{\frac{\text{Ingresos Explotacion}}{\left(\frac{\text{Deudores Final} + \text{Deudores Iniciales}}{2}\right)}}$
Periodo Medio de Pago	$PMP = \frac{365}{\frac{\text{Consumos Materiales} + \text{Existencias Finales} - \text{Existencias Iniciales}}{\left(\frac{\text{Acreedores Final} + \text{Acreedores Iniciales}}{2}\right)}}$
Periodo Medio de Maduración Económico	$PMME = PMA + PMC$
Periodo Medio de Maduración Financiero	$PMMF = PMME + PMP$

Fuente: *Elaboración propia.*

El motivo de la elección de esta ratio, a pesar de su variabilidad, es que aporta indirectamente información sobre la verdadera actividad de las empresas, y la tecnología o los procesos productivos que integra.

### Endeudamiento

El desequilibrio entre los recursos propios (presentes o futuros) y las necesidades de gasto e inversión, se compensa con el endeudamiento. Si hubiere equilibrio, situación atípica, la empresa sería plenamente autónoma. Por tanto, medir el endeudamiento es una manera de evaluar la autonomía para tomar decisiones financieras. De hecho, la ratio de autonomía financiera, relación entre los fondos propios y los pasivos, es la inversa del endeudamiento.

Nos indicará por cada unidad monetaria utilizada de recursos propios de la empresa, cuánto se utiliza de recursos ajenos, con lo que existe un rango óptimo para que se aproveche en suficiente medida de la financiación externa sin encontrarse amenazada por ella.

Tabla 6.2. Endeudamientos.

Ratio	Fórmula
Endeudamiento	$\text{Endeudamiento} = \frac{\text{PasivoFijo} + \text{PasivoLiquido}}{\text{FondosPropios}}$
Endeudamiento a Largo Plazo	$\text{EndeudamientoLP} = \frac{\text{PasivoFijo}}{\text{FondosPropios}}$
Endeudamiento a Corto Plazo	$\text{EndeudamientoCP} = \frac{\text{PasivoLiquido}}{\text{FondosPropios}}$

Fuente: Elaboración propia.

Diversos autores apuntan que valores de endeudamiento elevados se relacionan significativamente con mayores probabilidades de manipulación de la información contable. Es necesario comentar, pese a todo, que valores excesivamente bajos también pueden perjudicar la depuración de empresas de cara a mantener un conjunto de limitada variabilidad y serán consideradas como *outlier*. Esta conclusión es extensible para todas las siguientes variables que hacen referencia a las obligaciones de la empresa.

### Relación entre Capital Corriente y Cash Flow

Relaciona el Capital Corriente, que señala la capacidad de la empresa para hacer frente a sus compromisos a corto plazo y el cash-flow, que se refiere a la capacidad para generar recursos con el negocio y hacer frente a las obligaciones de un modo general. Está formado por el resultado, sin considerar la amortización que puede introducir distorsiones. Así, proporciona una medida de las obligaciones a corto plazo frente a los flujos de caja. Es digno de mención que los flujos de caja también han sido considerados indicativos de manipulaciones por algunos autores, en especial considerando su disminución frente a los años anteriores a aquel en que se adulteran los datos.

$$\frac{\text{CapitalCorriente}}{\text{CashFlow}} = \frac{\text{ActivoCirculante} - \text{PasivoLiquido}}{\text{ResultadoEjercicio} + \text{DotacionesAmortizacionInmovilizado}}$$

### *Liquidez*

Mide la capacidad inmediata de hacer frente a las deudas a corto plazo, no debiendo, según su definición, presentar valores muy superiores para evitar que existan activos circulantes ociosos, ni muy bajos asociados con dificultades para hacer frente a dichas deudas a corto plazo.

$$Liquidez = \frac{Tesoreria}{PasivoLiquido}$$

Algunos autores como Wuerges y Borba (2010), cuyas conclusiones comenta Rabazo (2017), sostienen su asociación negativa significativa con la probabilidad de fraude (cuando una tiende a ser alta, con la otra ocurre al revés).

### *Solvencia*

En este caso se hace referencia a la capacidad de la empresa de hacer frente a las deudas que deriven de su ciclo de explotación. Su valor tiene estrecha relación con los periodos medios anteriormente expuestos, por su importante vinculación con la actividad, con lo que se espera que el modelo encuentre este tipo de dependencias. Desde la perspectiva de la posible manipulación de los valores contables, una elevada variabilidad de esta ratio es un indicador de variaciones en las valoraciones de las existencias.

$$Solvencia = \frac{ActivoCirculante}{PasivoLiquido}$$

### *Prueba Acida*

Similar a la solvencia, sólo que se dejan de considerar las existencias en el numerador por ser un realizable condicionado a la venta previa, presentando por lo tanto un carácter más inmediato en cuanto a la capacidad de hacer frente a las obligaciones a corto plazo.

$$PruebaAcida = \frac{ActivoCirculante - Existencias}{PasivoLiquido}$$

### *Garantía*

También se denomina distancia a la quiebra y es un indicador de la solvencia global de la empresa en su conjunto, aunque se debe acompañar de otros indicadores más específicos para que gane en utilidad. Esto se debe a que los valores del activo hacen referencia a un pasado más o menos próximo, mientras que los pasivos son valores de compromisos futuros. Por ello, es necesaria una "actualización de valores" o regularización de partidas para que todos converjan en el presente. Si el valor es



próximo a la unidad, esto significa que las empresas no tienen capacidad para responder ante sus obligaciones.

$$\text{Garantía} = \frac{\text{Total Activo}}{\text{Pasivo Líquido} + \text{Pasivo Fijo}}$$

### *Relación entre Cash Flow y Activo Total*

En este caso, se relaciona el cash-flow, que resta al resultado la influencia distorsionadora de la amortización con el activo total, proporcionándose una medida del rendimiento final en forma de tesorería que se ha obtenido con el activo.

$$\frac{\text{CashFlow}}{\text{ActivoTotal}} = \frac{\text{Resultado} + \text{Dotaciones Amortización Inmovilizado}}{\text{ActivoTotal}}$$

Esta medida se puede considerar también como expresión de los devengos totales<sup>7</sup>, si se consideran años sucesivos. Según algunos autores, valores altos de estos se encuentran relacionados con empresas de políticas contables agresivas y tendentes a la manipulación de resultados. Además, se presentan a menudo devengos totales positivos los años anteriores a la manipulación de los resultados.

### *Servicio de la Deuda*

Está asociada a la disponibilidad de caja (cash-flow del numerador), para hacer frente a la devolución de la deuda, así como de los intereses. Está por tanto relacionado con la capacidad general de responder, las empresas, ante sus proveedores.

$$\text{Servicio De La Deuda} = \frac{\text{Resultado} + \text{Dotaciones Amortización Inmovilizado}}{\text{Deudas Financieras} + \text{Gastos Financieros}}$$

### *Rentabilidad Económica*

Conocida en la literatura anglosajona como ROA, supone el rendimiento de las inversiones totales al margen de su fuente de financiación y es de gran utilidad a la hora de comparar diferentes inversiones para una misma empresa, aunque también sirve para comparar varias distintas.

$$\text{Rentabilidad Económica} = \frac{\text{Impuesto Sociedades} + \text{Resultado} + \text{Gastos Financieros}}{\text{Activo Total}}$$

<sup>7</sup> Los devengos totales son la cantidad en que variarían las cuentas si los gastos e ingresos naciesen en el mismo momento que los pagos y cobros

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

Puede manifestar evidencia de intento de manipular los beneficios a través de valores inusualmente altos y especialmente, variaciones positivas importantes en comparación con las habituales, asociadas al posible maquillaje de beneficios bajos. Sin embargo, también pueden ser indicadores de manipulaciones valores especialmente bajos con consecuencias positivas sobre las obligaciones fiscales, dependiendo de los objetivos que muevan a sus gerentes en dicha actuación.

### *Margen*

Mide el beneficio obtenido en función de los ingresos derivados de las ventas realizadas y marca el tipo de estrategia seguida por la empresa, significando por lo general para valores altos, que esta busca su beneficio en la calidad y diferenciación de sus competidores

$$\text{Margen} = \frac{\text{Impuesto Sociedades} + \text{Resultado} + \text{Gastos Financieros}}{\text{Ingresos Explotacion}}$$

### *Rotación*

Mide la capacidad de los activos para generar ingresos a partir de la inversión y como el margen, está relacionada con la estrategia de negocio que sigue la empresa. Esta tiende a ser más eficiente en el uso de sus recursos y presentar más rotación, cuando compite buscando un mayor beneficio a través de la disminución de sus costes, y un mayor margen de maniobra en los precios.

$$\text{Rotacion} = \frac{\text{Ingresos Explotacion}}{\text{Activo Total}}$$

### *Rentabilidad Financiera*

Denominada ROE por la literatura anglosajona, relaciona el resultado después de impuestos con los fondos propios, comparando el resultado atribuido a la propiedad con los recursos aportados por dicha propiedad.

$$\text{Rentabilidad Financiera} = \frac{\text{Resultado}}{\text{Fondos Propios} - \text{Resultado}}$$

Junto a la rentabilidad económica, es otro importante indicador de la manipulación de la información contable, generalmente asociados los valores bajos, con mayor probabilidad de esta alteración.

### *Coste de la Deuda*

Está relacionado con los intereses de la deuda y considera los gastos debidos a ellos frente a las obligaciones totales a las que debe hacer frente la empresa.

$$\text{CosteDeuda} = \frac{\text{GastosFinancieros}}{\text{PasivoFijo} + \text{PasivoLiquido}}$$

### *Coste de la Deuda con Coste*

Frente al caso anterior, en este caso se consideran los gastos financieros sólo frente a las deudas que suponen dicho coste, excluyéndose las que no suponen coste alguno.

$$\text{CosteDeudaConCoste} = \frac{\text{GastosFinancieros}}{\text{AcreedoresLP} + \text{DeudasFinancieras}}$$

### *Apalancamiento*

En el ámbito anglosajón, el apalancamiento o *leverage* se refiere al endeudamiento. En este estudio se utiliza como la relación entre rentabilidad financiera y rentabilidad económica, ya que como se ha visto, difieren en los gastos financieros y los pasivos. Por tanto, el efecto de la deuda sobre la rentabilidad financiera será positivo si el coste la financiación es inferior a la rentabilidad económica:

$$\text{Apalancamiento} = \frac{\text{RentabilidadFinanciera}}{\text{RentabilidadEconmica}}$$

En cuanto a su relación con el fraude, debería de presentar una influencia similar al endeudamiento, con lo que sería de esperar una asociación positiva con el mismo (cuanto mayor sea, mayor será la probabilidad de fraude y viceversa).

### *Productividad de Personal*

Esta ratio relaciona los ingresos de explotación generados con los gastos de personal, midiendo de esta forma el rendimiento del capital humano de la empresa. Cuando se utilizan muestras con actividades homogéneas deberían mantener márgenes de variación estrechos. Si no fuese así, puede deberse a diferencias en los modelos de negocio o sesgos en los registros contables.

$$\text{ProductividadPersonal} = \frac{\text{IngresosExplotacion}}{\text{GastosPersonal}}$$

### Margen Bruto

En su definición, se trata de la diferencia entre los ingresos y los costes variables. Debido a las limitaciones de trabajar con información contable, en este trabajo se utiliza la relación entre los ingresos y los consumos de materias primas y aprovisionamientos, constituyendo por lo tanto una medida aproximada del margen medio obtenido por la empresa en su actividad.

$$\text{Margen Bruto} = \frac{\text{Ingresos Explotacion} - \text{Aprovisionamientos Materiales}}{\text{Ingresos Explotacion}}$$

Esta ratio, por último, se encuentra negativamente asociada a la ocurrencia de manipulaciones de la información contable, existiendo menor probabilidad de estas, cuanto mayor es su valor.

Se ha valorado la inclusión de otras variables que no se han sometido al proceso de eliminación de extremos de las anteriores, pero se han considerado susceptibles de ejercer una importante influencia en la condición de *outlier* de aquellas, que son:

### Tamaño

Este atributo se ha considerado en base al criterio, considerado por la Ley 14/2013 de Apoyo a los Emprendedores de Ingresos de Explotación o Cifra anual de negocios. Por lo tanto, es el valor de esta última cuenta para cada empresa el que se incluye adicionalmente.

Tabla 6.3. Clasificación de empresas según tamaños.

	Grande	Mediana	Pequeña	Micro
<b>Total, Activo (millones €)</b>	Más de 11,4	Entre 11,4 y 2,85	Menos o igual que 2,85	Menos o igual que 1
<b>Cifra anual de negocios (millones €)</b>	Más de 22,8	Entre 22,8 y 5,7	Menos o igual que 5,7	Menos o igual que 2
<b>Número medio de trabajadores</b>	Más de 250	Entre 250 y 50	Menos o igual que 50	Menos o igual que 10

Fuente: Elaboración propia a partir de la Ley 14/2013.

El motivo de su consideración es la evidente diferencia en el funcionamiento de empresas grandes, medianas y pequeñas, que influirá en la información contable que reportan y podría condicionar el interés o no de separarlas en el análisis. Por otro lado, la diferencia entre las empresas grandes y pequeñas a la hora de evaluar su sinceridad o no en los datos que presentan, ha sido estudiada ya por diversos autores con conclusiones encontradas al respecto pareciendo la hipótesis más realista la independencia de ambos factores señalada. Por ejemplo, en la tesis de la autora citada

al principio del presente subapartado, no influye en la probabilidad de manipulación de la información.

*Antigüedad de la empresa (edad)*

Mencionado por varios autores como variable relacionada con la incidencia de manipulaciones intencionadas de la información contable. Se tiende según aquellos, a una mayor probabilidad de alteraciones en la información para las empresas jóvenes que para las más antiguas.

## 7. Análisis y Resultados

La muestra de partida cuenta con 809 empresas extraídas aleatoriamente de la población, con ratios **clasificadas manualmente** según su naturaleza de *outlier* o no. Este etiquetado se ha realizado identificándose como anómalas y retirando del análisis las empresas con valores de ratio extremas, de forma que la varianza entre la media de la ratio para las restantes empresas se reduzca. Se repite este procedimiento hasta que las empresas restantes alcancen un umbral establecido por el analista, límite del carácter anómalo y no anómalo para esa ratio.

En este trabajo se pretende utilizar una red neuronal para automatizar este proceso. Para alcanzar una aproximación óptima al problema, el conjunto de partida se ha modificado para comparar el rendimiento del algoritmo según distintas configuraciones de los datos. Así, se han definido cuatro casos de estudio en función de dos criterios: el método de sustitución (imputación) de los datos ausentes de la muestra; y el grado de detalle en la detección de *outliers*.

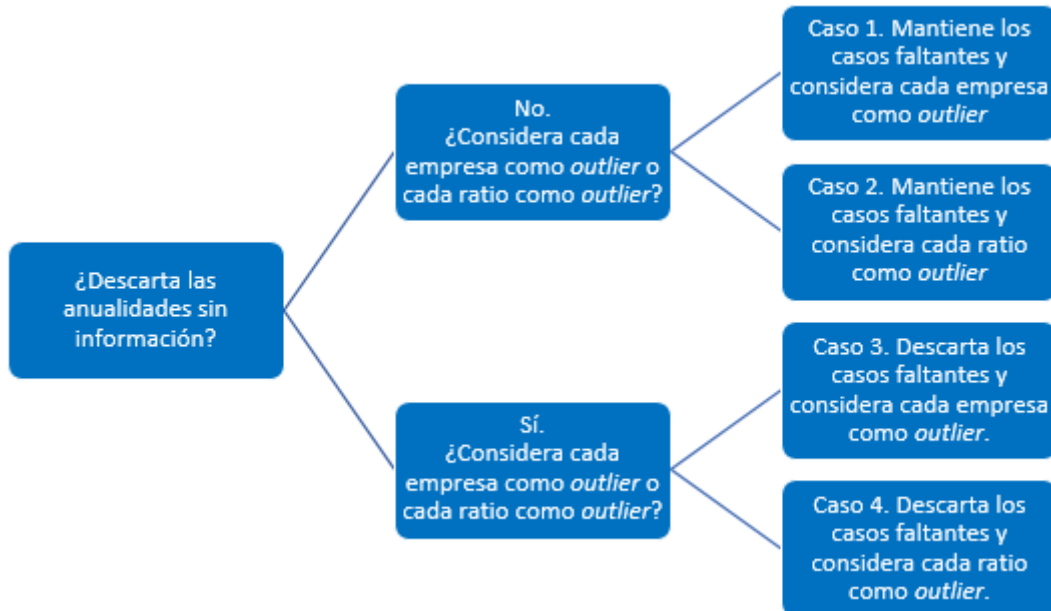
En primer lugar, la **sustitución de valores perdidos** es una necesidad habitual para datos reales, existiendo una variada metodología para enfrentarlo en todo tipo de ámbitos. En general, se recomienda identificar el mecanismo que origina los datos ausentes, valorando su tipología: si son valores perdidos de modo completamente aleatorio; si la ausencia es dependiente de sí misma (por ejemplo, si la variable con el valor ausente es más alta, es más probable que su valor no se recoja); si la ausencia depende de otras variables recogidas; o si depende de otras variables que no se han recogido.

Tanto en la población como en la muestra, se pueden identificar varios de estos mecanismos. Por ejemplo, buena parte de las empresas etiquetadas manualmente como anómalas carecen de datos para el Servicio de la Deuda, con lo que no serían valores perdidos aleatoriamente. También faltan valores de variables entre las empresas de edad anterior a los 10 años, que obligatoriamente carecen de cierta cantidad de las anualidades más lejanas. Del mismo modo, se observan algunos años sin datos en empresas de más de 10 años, con una mayor aleatoriedad aparente.

Gellman y Hill (2006), de cuya obra se extrajo la anterior categorización de valores perdidos, recomiendan utilizar modelos de imputación complejos como regresiones para resolver este problema cuando aquellos son condicionados y no aleatorios. Aquí, la cantidad de valores afectados no se ha considerado representativa sustituyéndose todas las ratios vacías por un valor próximo a 0 y las variables dependientes que definen la clasificación de las empresas, por 0,5 (equidistante entre 0 y 1). La abundancia de empresas con alguna anualidad completamente vacía también ha llevado a comparar el efecto que tendría retirar este conjunto de empresas, en la eficacia de la clasificación automática. Así, se tiene en cuenta el papel de la integridad (completitud) de la información contable como cualidad implicada en el rendimiento de la clasificación y en el Cuadro 7.1 se resumen las cuatro alternativas probadas, dos utilizan una **muestra completa de 809 empresas (casos 1 y 2)**, y otras dos una **muestra resultado de retirar de la anterior las empresas con alguna anualidad vacía de datos, con 536 empresas (casos 3 y 4)**.

En segundo lugar, se ha considerado interesante valorar **dos grados de detalle en cuanto al tipo de clasificación** que se intenta que imiten las redes neuronales. La clasificación manual distingue entre la **categoría de outlier o no para cada una de las ratios de cada empresa de la muestra**, con lo que se han elaborado dos modelos que intentan imitar este comportamiento (**casos 2 y 4**). Las alternativas **diferencian entre el carácter anómalo o no de cada empresa, sin entrar en el detalle de cada ratio (casos 1 y 3)**, valorando como anómalas las que tienen más de 5 ratios *outlier*.

Cuadro 7.1. Alternativas probadas en función del método de sustitución (imputación) de los datos ausentes y el grado de detalle en la detección de outliers.



Fuente: elaboración propia.

Para comparar los resultados de cada caso, se han obtenido los valores de la función de costes, y los parámetros de “accuracy”, “precision”, “recall” y “F1” en el conjunto de prueba de la Tabla 7.2. Tomando como referencia un mayor valor de F1 (más representativo del rendimiento equilibrado de los modelos en cuanto a falsos positivos y negativos), se puede comprobar que los casos menos detallistas (1 y 3, que valoran la condición de cada empresa, en general, como *outlier*) son los que aciertan más habitualmente en la clasificación. Por otro lado, se puede observar que la valoración de las anualidades con datos ausentes perjudica el rendimiento (casos 3 y 4), aunque es mucho menos perceptible cuando se distingue la condición de cada empresa como *outlier* sin entrar a clasificar cada ratio. Probablemente afecte la abundancia de ratios con clasificación normal cuando se estudia en detalle cada una, favoreciéndose los falsos negativos (empresas clasificadas como normales que son anómalas). Esto se debe a que el método de clasificación utilizado no funciona adecuadamente para la detección de anomalías cuando abundan los casos normales frente a los anómalos (o viceversa).

A partir de todo ello, se puede concluir que el caso 1 es el que mejores resultados proporciona.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

*Tabla 7.1. Resultados de las pruebas realizadas sobre las 4 alternativas.*

**Caso 1: Eliminación de anualidades con datos ausentes en la muestra e identificación del carácter de outlier de cada empresa en general**

Red neuronal de 1 capas ocultas y 100 elementos en cada capa oculta. Lambda 1.000000e-02.

	Real anómalo	Real normal		
Simulado anómalo	28%	10%	<b>Accuracy</b>	76.12%
			<b>Precision</b>	74.51%
Simulado normal	14%	48%	<b>Recall</b>	66.67%
			<b>F1</b>	70.37%

**Caso 2: Eliminación de anualidades con datos ausentes en la muestra e identificación detallada del carácter de outlier de cada ratio para cada empresa**

Red neuronal de 1 capas ocultas y 225 elementos en cada capa oculta. Lambda 10.

	Real anómalo	Real normal		
Simulado anómalo	2%	1%	<b>Accuracy</b>	94.51%
			<b>Precision</b>	74.73%
Simulado normal	5%	93%	<b>Recall</b>	23.40%
			<b>F1</b>	35.64%

**Caso 3: Conservación de anualidades con datos ausentes en la muestra e identificación del carácter de outlier de cada empresa en general**

Red neuronal de 3 capas ocultas y 100 elementos en cada capa oculta. Lambda 3.000000e-01.

	Real anómalo	Real normal		
Simulado anómalo	28%	11%	<b>Accuracy</b>	75.74%
			<b>Precision</b>	72.15%
Simulado normal	13%	48%	<b>Recall</b>	67.86%
			<b>F1</b>	69.94%

**Caso 4: Conservación de anualidades con datos ausentes en la muestra e identificación detallada del carácter de outlier de cada ratio para cada empresa**

Red neuronal de 3 capas ocultas y 600 elementos en cada capa oculta. Lambda 3.

	Real anómalo	Real normal		
Simulado anómalo	2%	1%	<b>Accuracy</b>	83.12%
			<b>Precision</b>	67.75%
Simulado normal	16%	81%	<b>Recall</b>	11.90%
			<b>F1</b>	20.24%

*Fuente: elaboración propia.*



Para explicar el error que persiste en el mejor modelo, es relevante conocer su tipología y cómo se obtuvieron los casos, antes de analizar las empresas en las que se equivocó.

Los modelos de redes neuronales consisten en vectores de pesos, obtenidos tras el entrenamiento del programa con los valores de las variables dependientes e independientes conocidas, de un conjunto de ejemplos o empresas (aquí el 50% de las muestras). Después del entrenamiento se pueden aplicar los pesos a nuevas variables independientes para clasificar casos distintos de los de entrenamiento. Así, con el 25% de los casos restantes de las muestras fuera del conjunto de entrenamiento, el conjunto de prueba, se han calculado los rendimientos de los modelos de la Tabla 7.2, para compararlos entre sí. El restante 25% forma parte del conjunto de validación. Para ejecutar cada caso de la Tabla 7.2 no se entrena un solo modelo por cada configuración de datos, sino varios de distinto nivel de complejidad modificando varios parámetros (lambda, número de capas y de elementos por capa) para elegir el mejor modelo posible. La evolución al respecto del caso 1 se ilustra en las Gráficas 7.4 y 7.5, que muestran cómo las redes más sencillas (menos capas y elementos en cada capa), proporcionan el menor coste o error. Si la red es demasiado compleja presentará errores de varianza y si es demasiado sencilla, de sesgo.

Por último, se ha representado la curva de aprendizaje para cada caso (Gráfica 7.3 para el caso 1), resultado de entrenar varias redes con conjuntos de entrenamiento formados por un número creciente de empresas hasta alcanzar el conjunto de entrenamiento completo. En la curva, se refleja para cada red el valor de la función de coste en el conjunto de validación y de entrenamiento, para identificar si sus carencias se deben a la varianza (relacionada con la cantidad de datos disponible y la capacidad de generalizar los resultados para empresas fuera del conjunto de entrenamiento) o al sesgo (relacionado con el diseño, es decir, el nivel de complejidad del modelo o la elección de las variables independientes). Se puede observar que el modelo apenas puede mejorar en cuanto a la varianza, pues con más ejemplos de entrenamiento, el error se estabiliza en torno a 0.5, y los valores cercanos del error de entrenamiento y validación en la mitad derecha de la gráfica, reafirman la predominancia del sesgo. Dado que ya se han probado diversos niveles de complejidad, la mejora del modelo podría consistir en limitar las variables independientes o equilibrar el número de casos de entrenamiento con valores normales frente a los anómalos, para cada ratio.

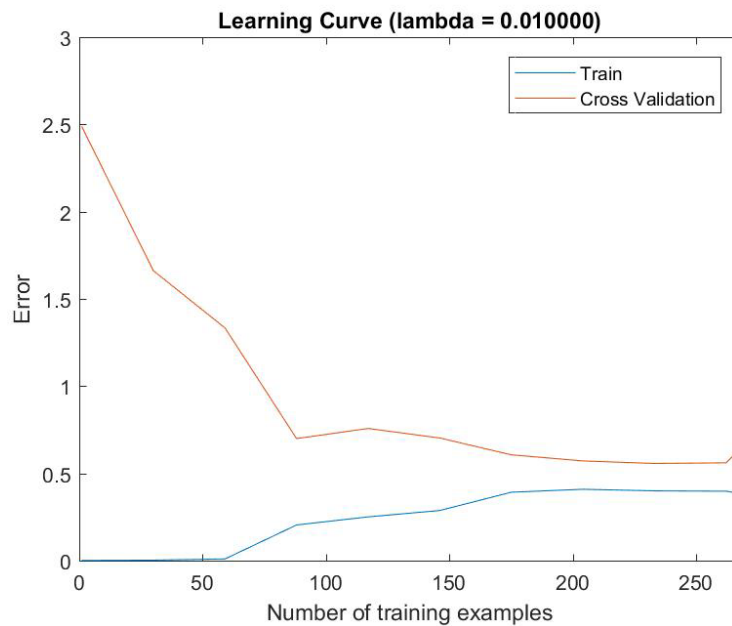
En la Tabla 7.6. se representan los parámetros de rendimiento del modelo óptimo del caso 1, calculados tanto para el conjunto de entrenamiento como el de prueba. Tienen valores similares de F1, aunque ligeramente superior para el conjunto de entrenamiento. Esto refleja la escasa incidencia de los errores de generalización en este modelo final.

El modelo del caso 1 se condensa en una matriz de pesos obtenida tras su entrenamiento. A partir de la clasificación del conjunto de prueba (134 empresas), **se analizarán en adelante los patrones de comportamiento más notorios de las empresas mal clasificadas a partir de 5 gráficas que representan 8 ratios**. Después, se tratarán de esclarecer los motivos de estos errores recurriendo al conjunto de entrenamiento, concluyéndose con el estudio de cada empresa mal clasificada.

Se ha representado la primera Gráfica 7.7, (Periodo Medio de Almacén, PMA e Ingresos de Explotación de 2014), por la notoriedad de un patrón reconocido en los datos. **Las empresas de menor tamaño (2 millones de euros de ingresos de explotación) y periodo medio de almacén (200 días), constituyen aproximadamente la mitad de las mal clasificadas**. Esto está relacionado con el principio de coste-beneficio de la calidad de la información contable y permite deducir la operativa habitual de estas compañías que almacenan lo mínimo posible, ajustando sus compras a la demanda.


## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

Gráfica 7.1. Curva de aprendizaje del "Caso 1: Eliminación de anualidades con datos ausentes en la muestra e identificación del carácter de outlier de cada empresa en general".



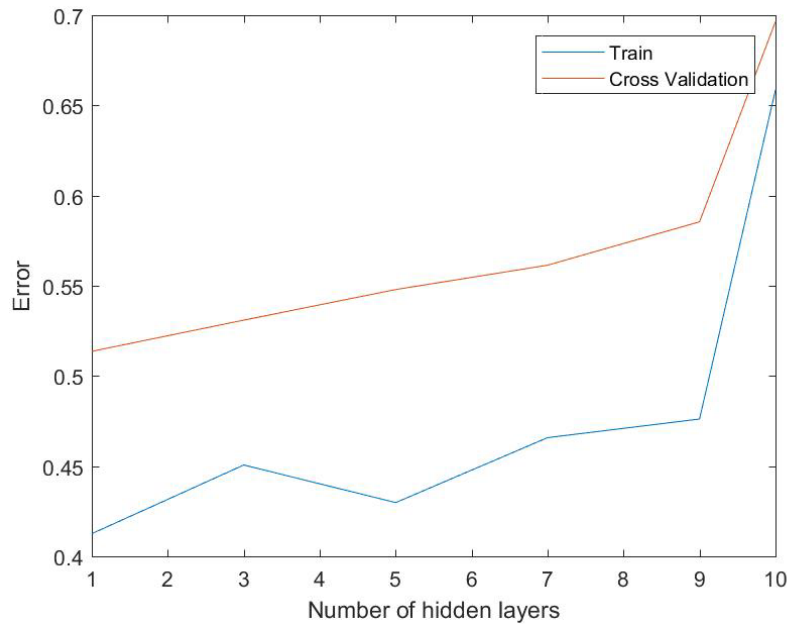
Fuente: elaboración propia.

Gráfica 7.2. Error vs. Complejidad (número de elementos en cada capa oculta), del "Caso 1: Eliminación de anualidades con datos ausentes en la muestra e identificación del carácter de outlier de cada empresa en general".



Fuente: elaboración propia.

Gráfica 7.3. Error vs. Complejidad (número de capas ocultas), para el “Caso 1: Eliminación de anualidades con datos ausentes en la muestra e identificación del carácter de outlier de cada empresa en general”.



Fuente: elaboración propia.

Tabla 7.2. Resultados del “Caso 1: Eliminación de anualidades con datos ausentes en la muestra e identificación del carácter de outlier de cada empresa en general”.

Red neuronal de 1 capas ocultas y 100 elementos en cada capa oculta.  
Lambda 1.000000e-02.

F1: 70%. Resultados sobre el conjunto de prueba.

	Realidad	
	1	0
Simulación 1	28%	10%
Simulación 0	14%	48%

F1: 71%. Resultados sobre el conjunto de entrenamiento.

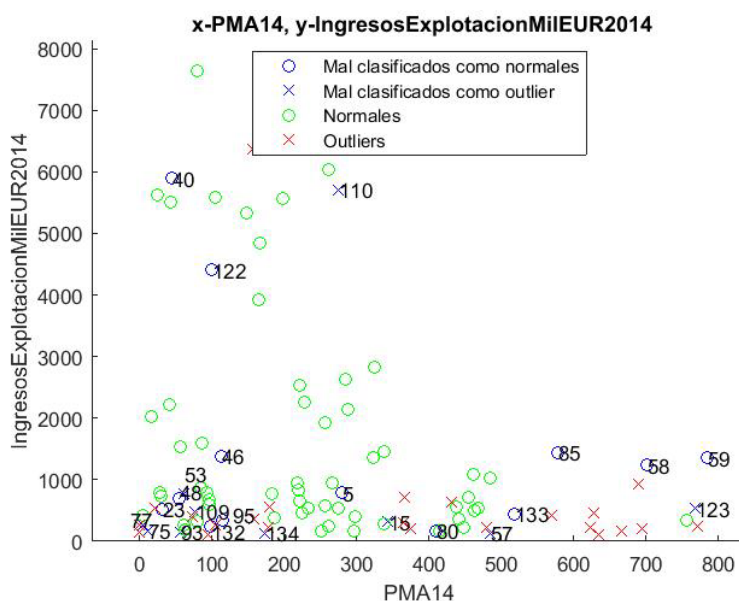
	Realidad	
	1	0
Simulación 1	25%	9%
Simulación 0	12%	54%

Fuentes: elaboración propia.

En las Gráficas 7.8, 7.9, 7.10 y 7.11, se representa a continuación el valor medio de los 10 años de estudio, de las siguientes parejas de ratios: Rentabilidad Económica (REcon) frente a Periodo Medio de Maduración Económica (PMME), Margen Bruto frente a Productividad de Personal, Rentabilidad Económica frente a Solvencia y Rentabilidad Económica frente a Endeudamiento. Se destacan las 134 empresas del conjunto de prueba con círculos, para las clasificadas en el caso 1 como normales y con aspas para las clasificadas como anomalías. Se sigue además un código de colores: las empresas rojas y verdes corresponden a empresas correctamente clasificadas con referencia al etiquetado manual anterior a la aplicación del algoritmo; y las azules son las incorrectamente clasificadas.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

Gráfica 7.4. Periodo Medio de Almacén (PMA) e Ingresos de Explotación de 2014




Fuente: elaboración propia a partir de datos de SABI (2017). Para evaluar de forma visual la distribución de los outliers de forma transversal, se han representado gráficas de parejas de ratios, en las que se distinguen las empresas clasificadas como outliers (x) y no outliers (o) por el algoritmo, así como aquellas que fueron mal clasificadas (color azul, el símbolo es el propio de la clasificación, el valor etiquetado "real" sería el contrario).

A partir de las gráficas se han identificado varias agrupaciones posibles de empresas mal clasificadas (azul). Son de destacar sus subactividades, dedicándose la mayoría a la fabricación de otros muebles y muebles de cocina en proporción similar. También hay empresas dedicadas a la fabricación de colchones, muebles de oficina de comercios, etc.


- Un primer bloque se distingue por presentar **combinaciones contradictorias de las tres ratios más ponderadas por el modelo a la hora de generar la clasificación final** (endeudamiento, PMME y rentabilidad económica). Se ha agrupado a su vez estas empresas según las ratios con un carácter más extremo, y justifican tanto falsos negativos (incorrectamente clasificados como normales), como falsos positivos (incorrectamente clasificados como anómalos):
  - Un subgrupo cuenta con **periodos medios de almacén extremos por su elevado valor** (y a menudo también otros periodos medios). Además, como refleja, el el Cuadro 7.12 respecto al conjunto de entrenamiento, generalmente no presentan anomalías en otras ratios. El número de clasificaciones *outlier* y normal en el conjunto de entrenamiento en cuanto a esta ratio es equilibrado, y las tres posibles estrategias a seguir por las empresas (margen, rotación y focalización) aparecen en igual proporción.
  - Otro subgrupo basa su carácter de *outlier* en el **endeudamiento, con unos valores más altos que la mayoría de las empresas**.

Gráfica 7.5. Periodo Medio de Maduración Económica (PMME) frente a Rentabilidad Económica (REcon).



Fuente: elaboración propia a partir de datos de SABI (2017). Para evaluar de forma visual la distribución de los outliers de forma trasversal, se han representado gráficas de parejas de ratios, en las que se distinguen las empresas clasificadas como outliers (x) y no outliers (o) por el algoritmo, así como aquellas que fueron mal clasificadas (color azul, el símbolo es el propio de la clasificación, el valor etiquetado “real” sería el contrario).

Gráfica 7.6. Margen Bruto frente a Productividad de Personal.




Fuente: elaboración propia a partir de datos de SABI (2017). Para evaluar de forma visual la distribución de los outliers de forma trasversal, se han representado gráficas de parejas de ratios, en las que se distinguen las empresas clasificadas como outliers (x) y no outliers (o) por el algoritmo, así como aquellas que fueron mal clasificadas (color azul, el símbolo es el propio de la clasificación, el valor etiquetado "real" sería el contrario).



## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

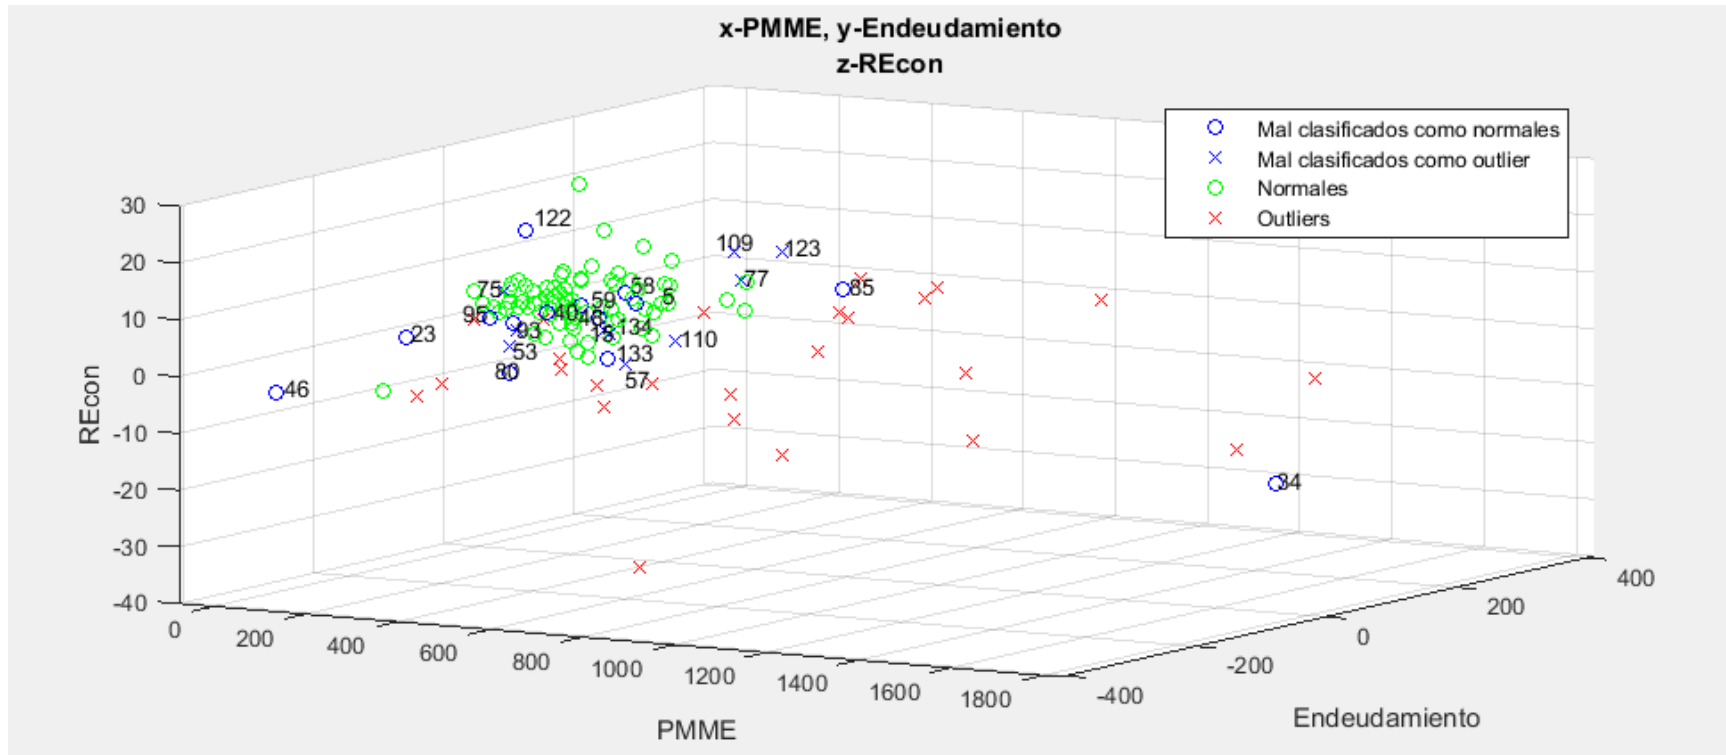
Gráfica 7.8. Rentabilidad Económica frente a Endeudamiento.



Fuente: elaboración propia a partir de datos de SABI (2017). Para evaluar de forma visual la distribución de los outliers de forma trasversal, se han representado gráficas de parejas de radios, en las que se distinguen las empresas clasificadas como outliers (x) y no outliers (o) por el algoritmo, así como aquellas que fueron mal clasificadas (color azul, el símbolo es el propio de la clasificación, el valor etiquetado "real" sería el contrario).



Gráfica 7.9. Representación de las ratios con más empresas etiquetadas como outlier: PMME, Endeudamiento y Rentabilidad Económica (REcon).



Fuente: Elaboración propia.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

- Un segundo bloque combina **empresas mal clasificadas como normales** que deberían ser *outliers* por el **alto servicio de la deuda, liquidez, solvencia..., o endeudamientos bajos**. En él la dificultad se debe a que, en el conjunto de entrenamiento, pocas compañías tienen etiquetadas estas ratios como *outlier*. Además, otras variables que permiten extraer conclusiones sobre la operativa productiva real de las empresas, como los periodos medios, poseen valores cercanos a la mayoría. Esto último puede contar con el **incentivo de ocultar las ventajas competitivas**, delatadas por la situación favorable de las ratios outlier.
- El tercer bloque recoge empresas con una **clasificación incorrecta en función del etiquetado manual patrón de referencia, pero sobre los que existen buenas razones para creer que pueden ser outliers**. Sus productos implican procesos productivos diferentes de los habituales en el sector: carpintería, diseño de interiores e instalación de mobiliario. Lo mismo sucede con las materias primas, distintas de las habituales: telas, maderas y sucedáneos sintéticos. Sin embargo, hay otras empresas no identificadas a pesar de las mismas diferencias.

La justificación de cada una de dichas clasificaciones erróneas requeriría la aplicación de algoritmos de extracción de reglas (CRED, TREPAN...) para esclarecer cómo interaccionan las variables para proporcionar una salida. Sin embargo, su escaso desarrollo dista mucho de desterrar la percepción extendida sobre las redes neuronales como cajas negras en las que sólo se conocen entradas y salidas. Aquí se recurre al conjunto de entrenamiento para intentar explicar los errores del algoritmo, destacándose tres características:

- Los **periodos medios son la ratio más abundante del conjunto de entrenamiento, con posibilidad de ser exclusiva causante del carácter outlier en las empresas, seguidos por endeudamientos y rentabilidades**.
- Existe un **grupo de ratios que no poseen empresas outliers etiquetadas o cuentan con muy pocas**. Son: productividad, capital corriente entre cash flow, apalancamiento, coste de la deuda, cash flow entre activo total, liquidez, solvencia y prueba ácida.
- Existen **variables como el coste de la deuda con coste, que presentan abundantes valores ausentes**, y además podrían relacionarse con el carácter de anomalía de las empresas que cuentan o carecen de ellos.

Cuadro 7.2. Ratios de las empresas etiquetadas, pertenecientes al conjunto de entrenamiento.

Conjunto de entrenamiento (268 ejemplos)	
Con más de 2 ratios <i>outlier</i> en:	
Periodos medios.	71%
El 49% de las empresas etiquetadas como <i>outlier</i> , tienen menos de 2 ratios etiquetadas <i>outlier</i> , diferentes de los periodos medios.	
Endeudamiento.	32%

**El 29% de empresas *outlier* tienen menos de 2 ratios *outlier* en periodos medios:**

Más de 2 <i>outlier</i> en rentabilidades, margen o rotación.	54%
Más de 2 <i>outlier</i> en endeudamiento.	61%
Más de 2 <i>outlier</i> en endeudamientos o rentabilidades.	83%

**No presentan *outliers*:**

Capital Corriente entre Cash Flow.  
Productividad.  
Apalancamiento.  
Coste de la deuda.

**Presentan escasos *outlier*:**

Cash Flow entre Activo Total.	1 caso o empresa
Liquidez.	1 caso o empresa
Solvencia.	3 casos o empresas
Prueba ácida.	2 casos o empresas

**Datos faltantes importantes en coste de la deuda con coste:**

45% de las anomalías del conjunto de entrenamiento.  
64% de las empresas del conjunto de entrenamiento con datos perdidos en esta ratio son anomalías.  
35% del total del conjunto de entrenamiento.

*Fuente: Elaboración propia.*

A continuación, se analizan pormenorizadamente empresas correspondientes a cada una de las agrupaciones comentadas.

Se comienza dividiendo el primer bloque de ***combinaciones contradictorias de las tres ratios más ponderadas por el modelo (endeudamiento, PMME y rentabilidad económica), a la hora de generar la clasificación final***, según las ratios más extremas:

- En cuanto a valores extremos de periodos medios, destacan las empresas identificadas con los números 34, 85 y 57:
  - La empresa 34, clasificada incorrectamente como normal, se dedica al comercio y fabricación de todo tipo de artículos de madera, con unos 139.000 euros de facturación. En las gráficas se observa una posición distante del centro de las agrupaciones más densas, rodeada habitualmente de casos correctamente clasificados como anómalos. Se asimila en cuanto al PMME, a otras empresas de la Gráfica 7.8 correctamente clasificadas como *outlier*, con garantía y solvencia notablemente más altas, pero un endeudamiento más bajo, intermedio respecto del resto, al igual que liquidez, solvencia y prueba ácida, que parece motivar el error.
  - La 85 recibió el mismo error en la clasificación (falso negativo), dedicándose a instalaciones y fabricación de mobiliario en general, y abarcando como mercado tanto otros negocios como hogares, con una facturación el último año de cerca de 1,5 millones de euros. Destaca su pertenencia a regiones propias de *outliers* en las gráficas de rentabilidad económica frente a PMME y margen bruto frente a productividad. En cuanto a endeudamientos, aunque

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

elevados frente a otras empresas bien clasificadas como normales, no son incompatibles con la clasificación normal, junto a la rentabilidad económica que sitúa esta compañía en una región definida por casos normales. Además, se asimila a otros casos bien clasificados como normales en la gráfica de rentabilidad económica y solvencia medias.

- El número 57 trabaja en la instalación de suelos, balcones... con 128.000 euros de facturación el último año y clasificada erróneamente como anómala. Los endeudamientos son intermedios y favorables respecto del resto de empresas del conjunto de prueba, al igual que garantía, liquidez, prueba ácida, solvencia o endeudamiento a corto plazo. En muchas gráficas se encuentra en áreas de baja densidad de empresas, rodeada de empresas clasificadas correctamente como anómalas (solvencia frente a rentabilidad económica, productividad frente a margen bruto, y rentabilidad frente a PMME), posible causa de la clasificación.
- En lo relativo a las empresas mal clasificadas por la red, con valores próximos a los extremos en cuanto a endeudamiento alto, destacan las empresas con las referencias 109, 80 y 48:
  - La referencia 109 (incorrectamente clasificada como *outlier*), se dedica a la fabricación de mobiliario de oficina con una facturación cercana a los 500.000 euros. Se encuentra en un área donde predominan empresas normales para las gráficas que enfrentan rentabilidad económica con solvencia y PMME. Productividad y margen bruto dan pie a mayores dudas, destacando la productividad de personal alta que aproxima a la empresa a un grupo de normales correctamente clasificadas de la parte inferior derecha de la gráfica. Destacan como diferencias que parecen originar el error un endeudamiento a largo plazo muy elevado respecto del resto, junto con una rentabilidad económica en la última gráfica, que la sitúa en una frontera entre regiones con distintas etiquetas.
  - El número 80 se dedica a la fabricación de mobiliario para cocinas y tiene una facturación de 168.000 euros. Es un falso negativo (mal identificado como normal), próximo a regiones en las que las empresas clasificadas como anómalas son abundantes en tres de las gráficas. Son destacables los valores bajos de liquidez, solvencia, prueba ácida, y sobre todo rentabilidad económica, junto con los extremadamente altos de endeudamiento. Los periodos medios son similares a la mayor parte de las empresas acertadamente clasificadas como normales, y la red parece haberlos dado más peso frente a la ausencia de endeudamiento a largo plazo y a pesar de los valores anómalos restantes. Destaca su pertenencia a un grupo mal clasificado como normal, en la parte inferior izquierda de la gráfica que representa margen bruto frente a productividad.
  - El código 48 (falso negativo) trabaja en tapicería con unos ingresos el último año, de 700.000 euros. Se encuentra en límites entre regiones donde predominan cada una de las dos categorías posibles, aunque la productividad y margen bruto parecen apuntar más bien a su carácter de anomalía. La naturaleza anómala etiquetada se debe a los endeudamientos a corto plazo, extremadamente altos, aunque carece de deuda a largo plazo desde 2008. Sin embargo, la rentabilidad económica, margen y rotación

toman cifras habituales teniendo en cuenta el resto de las compañías, al igual que los periodos medios, que pueden haber motivado conjuntamente el resultado.

Se han identificado asimismo ciertas **empresas incorrectamente clasificadas como normales, pese a las posiciones extremas en sentido favorable de las ratios que indican la capacidad de hacer frente a sus obligaciones**, destacando a continuación la 122 y 40:

- El caso 122, mal clasificado como normal, aparece en posiciones muy alejadas y más favorables respecto del resto en las cuatro gráficas. Cuenta con el tercer dato de mayor facturación entre las mal clasificadas el último año analizado, cerca de 4,5 millones de euros. Es destacable el producto especializado que fabrica, camillas para la prestación de servicios como fisioterapia... Destaca la justificación del etiquetado manual como *outlier* en base a la solvencia, prueba ácida y liquidez, con escasos *outliers* marcados en el conjunto de entrenamiento y también en base a algunos valores de servicio de la deuda y rentabilidad financiera, aunque la rentabilidad económica y los valores bajos de endeudamiento también se alejan bastante del resto de empresas. Sin embargo, los periodos medios, a los que el modelo otorga un gran peso por la abundancia de *outliers* etiquetados, se encuentran en un rango de valores propio de empresas normales, que probablemente hayan motivado el error, como ocurría con la 80.
- El número 40 es muy similar a los grupos de empresas correctamente clasificadas como normales en cada una de las gráficas, e incluso el comportamiento frente a las obligaciones a corto plazo se encuentra en valores intermedios respecto del resto de empresas, lo que posiblemente motive la clasificación, aunque no sea correcta. El carácter *outlier* se lo debe a que, a partir del año 2008, su servicio de la deuda se dispara con valores extremos para todos los años. También destaca que se dedica a fabricar somieres, contando con el dato mayor de facturación el último año (5,8 millones de euros), de entre los errores de clasificación encontrados.

Se puede citar un tercer y último grupo integrado por dos empresas erróneamente clasificadas como anómalas, si se toma como referencia el etiquetado manual patrón que se ha valorado hasta ahora (la 75 y 110). Se han encontrado razones para justificar una **clasificación correcta del modelo a pesar del etiquetado contrario, relacionada con las diferencias en las actividades frente al sector**.

- El caso 75 (mal categorizado como *outlier*) factura unos 176.000 euros y se dedica a fabricación de mobiliario metálico, especialmente para establecimientos comerciales. Sólo presenta una posición propia de empresas *outlier* en la gráfica que enfrenta margen bruto y productividad. Liquidez, prueba ácida y solvencia son mayores que la mayoría del sector, aunque por la abundancia de clasificaciones normales en el conjunto de entrenamiento, es de entender que sea esta la categoría que el modelo tiende a asignar más. A pesar de los endeudamientos nulos a largo plazo, el general está entre los de la mayoría de las empresas correctamente clasificadas como normales, al igual que la rentabilidad económica y el PMME, con lo que es poco probable que el margen bruto exclusivamente, con valores propios de muchas empresas *outlier*, sea el único responsable de la clasificación final. Probablemente tenga más que ver con alguna combinación de valores de ratios que diferencia esta compañía especialmente del resto, relacionada quizás con el distinto proceso productivo (trabaja exclusivamente con metales en vez de con tejidos y maderas), lo que subraya la posibilidad de una clasificación correcta.

## APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

- La empresa 110 (mal clasificada como anómala) se encuentra entre regiones favorables a uno u otro tipo de clasificación, salvo para la gráfica que representa margen bruto frente a productividad de personal, donde se sitúa en una región característica de empresas normales. El endeudamiento presenta valores bajos, propios de muchas empresas normales, destacando los nullos del largo plazo, cierta volatilidad en el servicio de la deuda y unas garantías muy altas respecto del resto. La rentabilidad económica y margen fluctúan en años recientes, con valores muy bajos respecto al resto, que posiblemente estén relacionados con la clasificación. Lo mismo ocurre con el PMME, alejado de la mayoría de las etiquetadas como normales. Esto último junto con los elevados ingresos de explotación por encima de los 5,5 millones de euros, y una actividad con peculiaridades, al dedicarse a la fabricación de muebles destinados al hogar, económicos y orientados a ser montados por el propio cliente, nos hace plantearnos que pudiera haber sido correctamente clasificada como *outlier*.

Como se ha podido comprobar, el análisis da el mayor peso a los valores de rentabilidad económica, endeudamiento y periodos medios, teniendo en cuenta que los escasos *outliers* entre solvencia, liquidez, servicio de la deuda... favorecen una clasificación normal.

Además de esta importancia de ciertas variables por el equilibrio entre etiquetados normales y anómalos en el conjunto de entrenamiento, y de la sensibilidad a la ausencia de datos para determinadas ratios, se pueden extraer algunas **conclusiones adicionales**:

- Es posible que la escasez de ejemplos etiquetados en el conjunto de entrenamiento con sólo una ratio etiquetada en varios años consecutivos como *outlier* (periodo medio de almacén y endeudamiento), hayan motivado parte de los errores.
- La variabilidad de las ratios entre años consecutivos para las mismas empresas en el conjunto de entrenamiento, posiblemente también hagan más difícil la identificación de patrones en el conjunto de prueba, especialmente en algunas variables como los periodos medios.
- Existe una serie de empresas con productividades y margen bruto bajos, que tienden a clasificarse como normales a pesar de tratarse de empresas *outlier*, siendo ejemplos la 40 o la 80.
- La red neuronal del modelo es capaz de identificar estructuras en cuanto a las variables y su distribución temporal, que caracterizan las actividades y le permiten diferenciar empresas *outliers* más allá de los valores individuales de cada ratio.

En el siguiente apartado se resumirán las principales conclusiones del trabajo en base a la selección del modelo y los resultados de su aplicación, previamente desarrollados. Se comienza mencionando la utilidad para los usuarios de la información contable de la herramienta, para proseguir con los distintos aspectos aprendidos a lo largo de la realización del trabajo, finalizando con un comentario sobre su contexto e implicaciones.

## 8. Conclusiones y limitaciones

### 8.1. CONCLUSIONES

En primer lugar, lo más relevante es señalar que las pruebas confirman la potencial utilidad para los usuarios información financiera de la herramienta en torno a la que gira el trabajo. Se puede justificar esto, fundamentalmente por los valores altos de F1 (70%), índice de aciertos del modelo que tiene en cuenta el equilibrio entre falsos positivos y negativos. Además, en un segundo entrenamiento los resultados mejoraron, consiguiéndose tan sólo 24 empresas mal clasificadas de las 135 analizadas. De esas 24, sólo 3 (12.5%) tienen unos datos de ingresos de explotación para el último año de entre 4 y 6 millones de euros, 4 (16.7%) de entre 1 y 2 millones de euros y el resto se sitúan por debajo de 1 millón de euros, con 6 (25%) entre 100 y 200 mil euros. Por esto, se considera que los errores que comete no perjudican demasiado la utilidad de la herramienta.

Es importante recordar el punto de partida que se eligió para el trabajo, en base al concepto de calidad de la información, basado en el cumplimiento con determinadas de sus cualidades. Destacan entre estas la relevancia o utilidad, y la fiabilidad o ausencia de errores. Su cumplimiento se identifica con la variabilidad de los datos que se manifiesta en múltiples dimensiones, correspondientes con las ratios consideradas, y cuanto mejor acotada se encuentre, mejor se responderá a los fines de los usuarios de la información. En la práctica, la evaluación de calidad se resume en identificar *outliers*.

Un ejemplo de la importancia de la calidad de la información así definida, son los informes que realizan firmas de análisis de datos financieros, destapando escándalos como el de Gowex (Gotham City Research LLC 2014). Estos han sido identificados a menudo por la distancia de las compañías respecto de otras de su sector, en cuanto a determinadas ratios, en el caso anterior, por ejemplo, por los ingresos. La herramienta aquí propuesta imita la clasificación manual de las ratios de un conjunto de empresas con etiquetas *outlier* y no *outlier*, automatizándola para reducir el coste de procesado previo de los datos al. Diferencia así entre un grupo con valores uniformes que permiten extraer conclusiones sobre el comportamiento general del sector y otro con valores extremos relacionados con ventajas competitivas potenciales, reportes erróneos de información...

Es digno de mención que la herramienta pertenece a los ámbitos del análisis de big data y del aprendizaje automático. El informe sobre el futuro del trabajo del WEF (2018), apunta a que estas prácticas serán integradas respectivamente por el 85% y el 73% de los negocios para el año 2022. Sin embargo, en la proyección futura de estas técnicas junto con otras relacionadas, como el IoT (Internet of Things), robótica, etc. en la transformación de procesos y servicios, se presume una destrucción de empleo que despierta abundantes temores. Pese a todo, el informe transmite esperanza por el surgimiento de nuevos empleos relacionados con estas nuevas tecnologías (11% para 2022), mayor que la destrucción de empleos existentes (10%). Además, subraya que la tendencia en la implantación de técnicas relacionadas con la automatización es más proclive a potenciar las capacidades de los trabajadores que a sustituirlos completamente. Señala que está más orientada a tareas rutinarias de los trabajos, que a sustituir íntegramente la labor realizada en los puestos o perfiles afectados. De este modo, se cita un estudio del McKinsey Global Institute<sup>8</sup>

<sup>8</sup> Citado por WEF 2018

(2017) según el que dos tercios de los actuales puestos de trabajo poseen al menos un 30% de tareas automatizables con tecnología actualmente disponible, y un tercio cuenta con más del 70%.

En relación con todo esto, se destaca también la necesidad de la actualización de los conocimientos de los actuales trabajadores, respondiendo los empleadores en la encuesta asociada al informe, que para 2022 el 54% de los empleados precisarán de formación adicional. De estos estiman que el 10% necesitará formación de más de un año, el 9% de entre 6 meses y un año, y el 35% de hasta 6 meses.

Se pueden citar otros informes nacionales como el del CES (2018), que hacen referencia al mismo fenómeno de automatización de tareas gracias fundamentalmente a la digitalización, y su impacto tanto en la destrucción de empleo, como la creación de nuevos puestos de trabajo. Se menciona un potencial crecimiento económico a largo plazo, que puede conservar el empleo y potenciar el consumo, gracias al aumento de las ventas y mejora en la situación de las compañías derivada de la propia automatización. También se refiere a la posible reducción de la jornada laboral, como una oportunidad que, combinada con la aparición de nuevos mercados o el abaratamiento de los costes de producción, permitirían fomentar el autoempleo y la creación de nuevas pymes.

Es especialmente digna de destacar la valoración que se hace de la eficiencia económica de la automatización en relación con el interés de su adopción por las empresas. Para muchas tareas, la contratación de personal humano puede resultar más rentable económicamente que la inversión en tecnología que lo sustituya, circunstancia que posiblemente limite la velocidad de implantación de determinados avances.

El desarrollo, mejora y uso de herramientas como la estudiada en el trabajo, es un ejemplo más de estos avances relacionados con la automatización. Cuenta con potencial para reducir el tiempo de pretratamiento de los datos para el trabajo de los analistas, pero requiriendo aún de su intervención para conseguir una utilidad real. Se manifiesta la necesidad de una **revisión manual de los resultados en el caso, por ejemplo, de la aplicación del modelo que se ha conseguido entrenar al resto de la población de estudio**. Pueden ser de ayuda gráficas anteriores, como las que enfrentan rentabilidad económica con periodos medios y endeudamiento. A continuación, se reflejan algunas recomendaciones al aplicar del último modelo entrenado (Caso 1) a otros datos del sector:

- Puede partirse del análisis de **ratios de endeudamiento demasiado bajos, o extremos superiores de la solvencia, liquidez y prueba ácida** para identificar posibles *outlier* identificados como normales, que la red es incapaz de detectar.
- Es importante el estudio de **empresas clasificadas como normales con márgenes brutos especialmente bajos**.
- Sería interesante añadir un análisis de **rentabilidades económicas, endeudamientos y periodos medios para localizar los valores en el umbral del comportamiento normal/anormal**.

Resultados dignos de mención obtenidos de la selección de alternativas y las características del modelo final seleccionado, son:

- El entrenamiento de modelos utilizando datos de todo el periodo analizado simultáneamente como variables de entrada da lugar a algoritmos de salida mejores que los entrenados a partir de los datos de cada año por separado.



- La consideración global del carácter de *outlier* de cada empresa, proporciona modelos mucho mejores que los que intentan identificar el carácter de *outlier* de cada ratio dentro de cada empresa.
- El sesgo, derivado de la elección de las variables y de los parámetros de complejidad de la red neuronal es el factor más determinante en cuanto al mejor o peor desempeño del modelo entrenado. La influencia del diseño se materializa además en las siguientes dos apreciaciones:
  - Las variables que no tienen un número de *outliers* y no *outliers* aproximadamente equilibrado en el conjunto de entrenamiento, tienden a ser una importante causa de error en las clasificaciones.
  - Es importante un correcto tratamiento de los datos faltantes en las distintas variables para mejorar los resultados del modelo, pudiendo resultar de ayuda eliminar las empresas que carecen de datos en alguna anualidad.
- La red es capaz de identificar como *outlier* correctamente a las empresas etiquetadas manualmente como normales, trascendiendo las variables concretas para evaluar patrones entre ratios y años consecutivos, que diferencian los procesos productivos de casos concretos frente a los comunes del sector.

Por otro lado, son dignas de subrayar algunas conclusiones adicionales de la aplicación del modelo entrenado a empresas del sector analizado, fuera del conjunto de entrenamiento:

- La mayoría de las empresas mal clasificadas son de escasa dimensión (hasta 2 millones de ingresos de explotación), algo importante en cuanto a la utilidad del modelo. La mitad tiene, además, bajo periodo medio de almacén, lo que ha de estar relacionado con la aplicación del principio de coste-beneficio a la hora de reportar información financiera y la operativa de las empresas pequeñas, con limitaciones en cuanto al coste que pueden asumir en relación con la acumulación de stocks.
- El modelo considera fundamentalmente las ratios de periodos medios, endeudamiento y rentabilidad económica para efectuar la clasificación de los *outlier*.
- La escasez de ejemplos etiquetados en el conjunto de entrenamiento con sólo una ratio etiquetada en varios años consecutivos como *outlier*, puede haber motivado parte de los errores.
- La variabilidad de las ratios entre años consecutivos para las mismas empresas en el conjunto de entrenamiento (especialmente marcada en variables como los periodos medios), posiblemente hagan más difícil la identificación de patrones.
- Existe un grupo de empresas con productividades y margen bruto bajos, que tienden a clasificarse como normales a pesar de tratarse en realidad de empresas *outlier*.

Algunas de estas conclusiones sobre la selección, características y aplicación de la herramienta objeto del presente trabajo, subrayan la necesidad de supervisión humana de la técnica para conseguir un resultado útil que pueda servir como punto de partida de análisis posteriores. Sin embargo, las limitaciones que hacen necesaria la intervención del analista en el uso de la herramienta también son incentivos para su mejora y se desarrollan en el siguiente apartado, proponiéndose soluciones.

## 8.2. LIMITACIONES

Se pueden citar limitaciones del trabajo relacionadas tanto con la metodología aplicada y sus posibilidades de perfeccionamiento como con la aplicación y grado de validez de los modelos obtenidos para los datos analizados, que se han abordado mediante simplificaciones y alternativas diversas por exceder su aplicación el alcance de este:

- En primer lugar, sería interesante encontrar otras características e indicadores de naturaleza contable o no, como el número de errores ortográficos de informes corporativos ya comentados, que puedan estar relacionados con la calidad de la información contable. Así, pudiera resultar conveniente probar la introducción de variables *dummy* de cara a introducir en el análisis la cualidad de la información contable relativa a la integridad o completitud de los datos, que se ha revelado importante en casos como los costes de la deuda que parecen ausentes especialmente en casos identificados como anómalos. De hecho, el debate para mejorar los resultados de los modelos de quiebra existentes, de naturaleza próxima a los utilizados en el presente proyecto, se encuentra centrado en la incorporación de **nuevas variables o el desarrollo en mayor detalle de algunas existentes, tratando de controlar otros factores que introducen ruido en el modelo** (como tendencias en el sector, condiciones macroeconómicas, impactos internos y externos, etc.).
- Los **“ensemble methods”**, son una familia de técnicas que reducen la dependencia del modelo de un conjunto de datos específico, mejorando la robustez y ayudando a conseguir mejores modelos. Así, resuelven el problema de consecución de mínimos locales en vez de globales de la función de costes de las redes neuronales. Destacan el bagging, boosting, random forests... Pueden combinar varios modelos independientes para resolver un problema, mediante una estrategia concreta, utilizando un mismo método o a varios distintos, que distinguen si el **“ensemble”** es homogéneo o heterogéneo. El objetivo es crear modelos acertados y diversos, introduciendo la suficiente aleatoriedad mediante la perturbación de los datos de entrenamiento, variables o parámetros, siendo estos últimos más o menos involucrados en función de la técnica utilizada. También sirven técnicas de **“smoothed bootstrap”**, que introducen ruido aleatorio, pudiendo generar nuevos casos para el conjunto de entrenamiento.
- También se ha de tener en cuenta que los datos utilizados aquí son una serie de variables contables recogidas anualmente, con lo que se podría hacer hincapié en la consideración del problema como el de un análisis de series temporales con sus propios condicionantes específicos (Gupta et al, 2014), utilizando metodologías similares a la aquí abordada como las **redes neuronales recurrentes** que podrían valorar en mayor medida el carácter confirmatorio y predictivo de los datos. Asimismo, resultaría de interés por su relación con la metodología aplicada el uso de **autoencoders** tanto en el tratamiento de datos faltantes, como en la tarea de detección de anomalías. Esto se debe a que permiten, a pesar de la necesidad de parámetros adicionales, números de casos muy desequilibrados entre ejemplos normales y anómalos conocidos. Se trata de un tipo de red neuronal que ya ha sido utilizada con éxito en este tipo de campo de detección de *outliers*, corrección de señales... incluso para el propio caso de datos financieros, como muestra el reciente trabajo de Scheyer M. et al. (2017).

## 9. Anexo I. Matriz de Correlaciones

Tabla 9.1. Matriz de correlaciones de las variables utilizadas en el análisis.

	PMA	PMC	PMP	PMME	PMMF	CC / CF	Liq	PA	Solv	E	E LP	E CP	Gar	CF / AT
PMA	1,00													
PMC	-0,01	1,00												
PMP	0,31	0,03	1,00											
PMME	0,72	0,02	0,13	1,00										
PMMF	0,43	0,00	-0,54	0,75	1,00									
CC / CF	0,25	0,02	0,09	0,12	0,05	1,00								
Liq	-0,01	0,01	0,00	-0,01	-0,01	0,00	1,00							
PA	-0,03	0,05	0,00	-0,02	-0,02	0,00	0,86	1,00						
Solv	0,01	0,03	-0,01	0,05	0,04	0,02	0,81	0,97	1,00					
E	0,16	-0,02	0,06	0,08	0,03	0,06	0,00	-0,01	0,00	1,00				
E LP	0,19	-0,02	0,07	0,09	0,03	0,07	0,00	-0,01	0,00	0,99	1,00			
E CP	0,13	-0,02	0,05	0,06	0,02	0,06	0,00	-0,01	-0,01	0,99	0,95	1,00		
GaR	0,00	0,02	0,00	0,02	0,02	0,01	0,75	0,93	0,97	-0,01	0,00	-0,01	1,00	
CF / AT	-0,04	0,00	-0,04	-0,06	-0,02	-0,01	0,05	0,10	0,08	-0,01	-0,01	0,00	0,07	1,00
SD	-0,02	0,00	0,00	-0,04	-0,02	0,00	0,01	0,01	0,00	0,00	0,00	0,00	-0,01	0,08
REcon	-0,03	0,01	-0,04	-0,06	-0,03	0,01	0,06	0,12	0,09	0,01	0,01	0,02	0,08	0,92
Marg	0,17	-0,13	0,06	0,03	-0,01	0,06	0,01	0,04	0,03	0,04	0,04	0,04	0,02	0,45
Rot	-0,10	-0,09	-0,02	-0,14	-0,10	-0,01	0,01	0,00	-0,01	-0,03	-0,03	-0,02	-0,02	0,07
RFin	-0,01	0,00	0,00	-0,02	-0,01	0,02	0,01	0,01	0,00	-0,02	-0,03	-0,01	0,01	0,15
CD	-0,02	0,01	-0,03	-0,02	0,01	0,01	0,28	0,41	0,48	0,02	0,02	0,02	0,50	0,08
CDC	-0,01	-0,01	0,00	-0,01	-0,01	-0,01	-0,01	0,00	0,00	0,00	0,00	-0,01	0,01	0,01
Apal	0,18	0,08	0,07	0,08	0,02	0,08	0,02	0,01	0,01	0,06	0,05	0,07	0,01	0,02
P Pers	-0,02	-0,01	0,01	-0,02	-0,02	0,00	0,02	0,01	0,01	0,07	0,09	0,05	0,00	0,02
M B	-0,57	0,01	-0,23	-0,11	0,02	-0,17	0,02	0,07	0,09	-0,13	-0,15	-0,10	0,07	0,13
Ingr	-0,04	0,06	0,00	-0,04	-0,04	0,00	0,02	0,05	0,02	0,00	0,00	0,00	0,02	0,18
Edad	0,02	0,07	0,01	0,07	0,05	0,08	0,02	0,12	0,14	0,01	0,01	0,00	0,13	0,10

APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

	<i>SD</i>	<i>REcon</i>	<i>Marg</i>	<i>Rot</i>	<i>RFin</i>	<i>CD</i>	<i>CDC</i>	<i>Apal</i>	<i>P Pers</i>	<i>M B</i>	<i>Ingr</i>	<i>Edad</i>
<i>PMA</i>												
<i>PMC</i>												
<i>PMP</i>												
<i>PMME</i>												
<i>PMMF</i>												
<i>CC / CF</i>												
<i>Liq</i>												
<i>PA</i>												
<i>Solv</i>												
<i>E</i>												
<i>E LP</i>												
<i>E CP</i>												
<i>GaR</i>												
<i>CF / AT</i>												
<i>SD</i>	1,00											
<i>REcon</i>	0,08	1,00										
<i>Marg</i>	0,09	0,48	1,00									
<i>Rot</i>	0,03	0,00	0,04	1,00								
<i>RFin</i>	0,00	0,16	0,08	-0,03	1,00							
<i>CD</i>	0,05	0,13	0,05	0,19	0,00	1,00						
<i>CDC</i>	0,01	0,02	0,01	0,06	0,01	-0,01	1,00					
<i>Apal</i>	0,00	0,02	0,06	0,00	-0,22	-0,01	-0,02	1,00				
<i>P Pers</i>	0,01	0,05	0,01	0,00	0,00	-0,02	0,00	-0,09	1,00			
<i>M B</i>	-0,01	0,04	-0,10	0,21	-0,04	0,21	0,02	-0,13	-0,05	1,00		
<i>Ingr</i>	0,01	0,21	0,12	-0,03	0,01	0,04	0,00	0,03	0,03	0,04	1,00	

*Leyenda:*

<b>PMA</b>	Periodo Medio de Almacén.
<b>PMC</b>	Periodo Medio de Cobro.
<b>PMP</b>	Periodo Medio de Pago.
<b>PMME</b>	Periodo Medio de Maduración Económica.
<b>PMMF</b>	Periodo Medio de Maduración Financiera.
<b>CC / CF</b>	Capital Corriente entre Cash Flow.
<b>Liq</b>	Liquidez.
<b>PA</b>	Prueba Ácida.
<b>Solv</b>	Solvencia.
<b>E</b>	Endeudamiento.
<b>E LP</b>	Endeudamiento a Largo Plazo.
<b>E CP</b>	Endeudamiento a Corto Plazo.
<b>GaR</b>	Garantía.
<b>CF / AT</b>	Cash Flow entre Activo Total.
<b>SD</b>	Servicio de la Deuda.
<b>REcon</b>	Rentabilidad Económica.
<b>Marg</b>	Margen.
<b>Rot</b>	Rotación.
<b>RFin</b>	Rentabilidad Financiera.
<b>CD</b>	Coste de la Deuda.
<b>CDC</b>	Coste de la Deuda con Coste.
<b>Apal</b>	Apalancamiento.
<b>P Pers</b>	Productividad de Personal.
<b>M B</b>	Margen Bruto.
<b>Ingr</b>	Ingresos.
<b>Edad</b>	Edad.

*Fuente: elaboración propia.*

## 10. Anexo II. Ratios y resultados del conjunto de prueba

Hoja de cálculo adjunta con título “Conjunto de Prueba Clasificado” en formato “.xlsx”.

## 11. Bibliografía

- AECA 2012. *Principios y normas de la contabilidad. Marco conceptual de la información financiera*. AECA: Madrid. [Consulta: enero 2018]. Disponible en:  
<http://www.aeca.es/old/pub/documentos/pc1r.pdf>
- AICPA 2017. *Addressing Challenges for Highly Subjective and Complex Accounting Areas*. Anti-Fraud Collaboration. [Consulta: marzo 2018]. Disponible en:  
<https://www.thecaq.org/file/2866/download?token=wti3JEdT>
- Atiya, AF 2001. Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results. *IEEE Transactions on Neural Networks*. 12(4), 929-935. DOI: <https://doi.org/10.1109/72.935101>. [Consulta: diciembre 2017]. Disponible en:  
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.86.3792&rep=rep1&type=pdf>
- Aziz MA y Dar HA 2006. Predicting corporate bankruptcy: where we stand?. *Corporate Governance*. 6(1), 18-33. DOI: <https://doi.org/10.1108/14720700610649436>. [Consulta: diciembre 2017]. Disponible en:  
[https://www.mathos.unios.hr/upravljanjejr/materijali/Aziz\\_Dar\\_Predicting\\_Corporate\\_Bankruptcy.pdf](https://www.mathos.unios.hr/upravljanjejr/materijali/Aziz_Dar_Predicting_Corporate_Bankruptcy.pdf)
- Barnett V, Lewis T 1994. *Outliers in Statistical Data*. John Wiley.
- Ben-Gal I 2005. Chapter 1: Outlier Detection. En: Maimon, O; Rockach, L. (Eds.) *Data Mining and Knowledge Discovery Handbook: A Complete Guide for Practitioners and Researchers*. ISBN 0-387-24435-2. [Consulta: diciembre 2017]. Disponible en:  
<http://www.eng.tau.ac.il/~bengal/outlier.pdf>
- Cátedra PYME 2017. *El sector de fabricación de muebles en España. Situación para la Industria 4.0*. Cátedra PYME: Cantabria. [Consulta: agosto 2018]. Disponible en:  
[http://www.expertoauditoria.es/wp-content/uploads/2018/05/43\\_IN\\_27\\_OPYME\\_Mueble2017\\_RevisadaNov-1.pdf](http://www.expertoauditoria.es/wp-content/uploads/2018/05/43_IN_27_OPYME_Mueble2017_RevisadaNov-1.pdf)
- Chandola V, Banerjee A, Kumar V. 2009. Anomaly detection: A survey. *ACM Computing Surveys*, 41(3), 1-58. DOI: <https://doi.org/10.1145/1541880.1541882>. [Consulta: diciembre 2017]. Disponible en:  
<http://cucis.ece.northwestern.edu/projects/DMS/publications/AnomalyDetection.pdf>
- Citron Research 2011. *Citron reports on Longtop Financial*. En: [citronresearch.com](http://citronresearch.com). [Consulta: diciembre 2017]. Disponible en:  
<http://citronresearch.com/citron-reports-on-longtop-financial-nyselt/>
- Consejo Económico y Social (CES) 2018. *Informe 03|2018 el futuro del trabajo*. ISBN: 978-84-8188-379-4. [Consulta: septiembre 2017]. Disponible en:

<http://www.ces.es/documents/10180/5461461/Inf0318.pdf>

- Dang Y 2011. *A Comparative Study of Bagging and Boosting of Supervised and Unsupervised Classifiers For Outliers Detection*. En: Wu Z (Dir) Master of Science in Electrical Engineering (MSEE) Thesis, Wright State University, Electrical Engineering. [Consulta: diciembre 2017]. Disponible en:  
[https://etd.ohiolink.edu/!etd.send\\_file?accession=wright1502475855457354&disposition=inline](https://etd.ohiolink.edu/!etd.send_file?accession=wright1502475855457354&disposition=inline)
- Eder Aceved M, Alexei Serna A, Edgar Serna M 2017. Principios y características de las redes neuronales artificiales. *Actas de ingeniería*.3:348-353. [Consulta: mayo 2018]. Disponible en:  
<http://fundacioniai.org/actas/Actas3/Actas3.40.pdf>
- Fang VW, Huang AH y Wang W 2017. Imperfect Accounting and Reporting Bias. *Journal of Accounting Research*. 55(4):919-962. DOI: <https://doi.org/10.1111/1475-679X.12170>. [Consulta: junio 2018]. Disponible en:  
[https://www.researchgate.net/publication/313848960\\_Imperfect\\_Accounting\\_and\\_Reporting\\_Bias](https://www.researchgate.net/publication/313848960_Imperfect_Accounting_and_Reporting_Bias)
- Ferrero Bermejo J 2014. *Mejora de la Eficiencia Energética de una Planta Fotovoltaica con la Detección Temprana de Fallos Mediante el Uso de Modelos Predictivos de Redes Neuronales Artificiales*. En: Crespo Márquez A, Gómez Fernández JF (Dir). Trabajo Fin de Máster del Máster Universitario en Organización Industrial y Gestión de Empresas. Escuela Superior de Ingeniería de la Universidad de Sevilla. [Consulta: mayo 2018]. Disponible en:  
<https://idus.us.es/xmlui/bitstream/handle/11441/27049/TFM-MOIGE-%20Jesus%20Ferrero%20Bermejo.pdf;sequence=1>
- Gillette J, Jayaraman S, Zimmerman J 2017. Accounting Restatements: Malfeasance and/or Optimal Incompetence?. [Consulta: diciembre 2017]. Disponible en:  
<https://sites.duke.edu/2016dukeuncfallcamp/files/2016/05/Jacquelyn-Gillette-1.pdf>
- Gellman A, Hill J 2006. Missing Data Imputation. En: Cambridge University Press (Ed.), *Data Analysis Using Regression and Multilevel/Hierarchical Models*. ISBN: 978-0521686891. [Consulta: enero 2018]. Disponible en:  
<http://www.stat.columbia.edu/~gelman/arm/missing.pdf>
- Gotham City Research LLC. 2014. *Let's Gowex: La Charada Pescanova (a Pescanova Charade)*. En: gothamcityresearch.com. [Consulta: diciembre 2017]. Disponible en:  
<https://www.gothamcityresearch.com/single-post/2014/07/01/Let%E2%80%99s-Gowex-La-Charada-Pescanova-a-Pescanova-Charade>
- Gupta M, Gao J, Aggarwal C, Han J 2014. Outlier detection for temporal data. *IEEE Transactions on knowledge and data engineering*. 28(9):2250-2287. DOI: <https://doi.org/10.2200/S00573ED1V01Y201403DMK008>, [Consulta: diciembre 2017]. Disponible en:  
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.352.3123&rep=rep1&type=pdf>

APLICACIÓN DE REDES NEURONALES EN LA EVALUACIÓN DE LA CALIDAD DE LA INFORMACIÓN CONTABLE

- Hawkins DM 1980. *Identification of outliers*. Chapman and Hall.
- IASB 2015. *Conceptual Framework for financial reporting*. IASB: London (United Kingdom). [Consulta: enero 2018]. Disponible en:  
<http://www.ifrs.org/-/media/project/conceptual-framework/exposure-draft/published-documents/ed-conceptual-framework.pdf>
- IASB 2008. *Statement of Financial Accounting Concepts No. 2*. [Consulta: enero 2018]. Disponible en:  
<http://www.fasb.org/cs/BlobServer?blobcol=urldata&blobtable=MungoBlobs&blobkey=id&blobwhere=1175820900526&blobheader=application/pdf>
- International Ethics Standards Board for Accountants (IESBA) 2005. *Code of ethics for professional accountants*. En: ifac.org [Consulta: Marzo 2018] Disponible en:  
<https://www.ifac.org/system/files/publications/files/ifac-code-of-ethics-for.pdf>
- McKinsey Global Institute 2017. *A Future That Works: Automation, Employment, and Productivity*. En: mckinsey.com [Consulta: septiembre 2018]. Disponible en:  
<https://www.mckinsey.com/-/media/mckinsey/featured%20insights/Digital%20Disruption/Harnessing%20automation%20for%20a%20future%20that%20works/MGI-A-future-that-works-Executive-summary.ashx>
- Martínez FJ y Somohano FM 2002. *Análisis de estados contables. Comentarios y ejercicios*. Anaya: Pirámide. ISBN: 84-368-1639-0.
- Rabazo Martín E 2017. *El fraude contable: una evidencia empírica*. J. Monterrey Mayoral (dir.), A. Sánchez Segura (dir.). Tesis doctoral, Universidad de Extremadura. [Consulta: diciembre 2017]. Disponible en:  
[http://dehesa.unex.es/bitstream/handle/10662/5587/TDUJEX\\_2017\\_Rabazo\\_Martin.pdf?sequence=1](http://dehesa.unex.es/bitstream/handle/10662/5587/TDUJEX_2017_Rabazo_Martin.pdf?sequence=1)
- Ricote-Gil F 2006. Las Redes Neuronales y la Gerencia de Riesgos. En: Fundación Mapfre, Instituto de Ciencias del Seguro (Eds.) *Gerencia de riesgos y seguros*. 94 (2), pp. 43-54. [Consulta: diciembre 2017]. Disponible en:  
[https://www.fundacionmapfre.org/documentacion/publico/pt/catalogo\\_imagenes/grupo.cmd?path=1028072](https://www.fundacionmapfre.org/documentacion/publico/pt/catalogo_imagenes/grupo.cmd?path=1028072)
- Rodríguez-López M, Piñeiro-Sánchez C, De Llano-Monelos P 2014. Determinación del riesgo de fracaso financiero mediante la utilización de modelos paramétricos, de inteligencia artificial, y de información de auditoría. *Estudios de Economía*. 41(2), 187-217. DOI: <https://doi.org/10.4067/S0718-52862014000200002>. [Consulta: diciembre 2017]. Disponible en:  
<http://www.scielo.cl/pdf/ede/v41n2/art02.pdf>
- Salchenberger L, Cinar E, Lash N. 2007. Neural networks: A new tool for predicting thrift failures. *Decision Sciences*. 23(4):899 - 916. DOI: 10.1111/j.1540-5915.1992.tb00425.x.
- Scheyer M, Sattarov T, Borth D, Dengel A, Reimer B 2017. Detection of Anomalies in Large Scale Accounting Data using Deep Autoencoder Networks. *arXiv:1709.05254 [cs.LG]* [Consulta: diciembre 2017]. Disponible en:



<https://arxiv.org/pdf/1709.05254.pdf>

- Unidad de Información y Análisis Financiero (UIAF) 2014. *Técnicas de minería de datos para la detección y prevención del lavado de activos y la financiación del terrorismo (LA/FT)*. ISBN: 978-958-58578-5-8. [Consulta: diciembre 2017]. Disponible en:

[http://www.urosario.edu.co/observatorio-de-lavado-de-activos/Archivos\\_Lavados/Tecnicas-de-mineria-de-datos-para-la-prevencion-de.pdf](http://www.urosario.edu.co/observatorio-de-lavado-de-activos/Archivos_Lavados/Tecnicas-de-mineria-de-datos-para-la-prevencion-de.pdf)

- Wells JT 2014. *Principles of fraud examination*. 4ª Edición. Hoboken, New Jersey: Wiley.
- World Economic Forum 2018. *The Future of Jobs Report 2018*. ISBN: 978-1-944835-18-7. [Consulta: septiembre 2018]. Disponible en:

[http://www3.weforum.org/docs/WEF\\_Future\\_of\\_Jobs\\_2018.pdf](http://www3.weforum.org/docs/WEF_Future_of_Jobs_2018.pdf)

- Wuerges AF, Borba JA 2010. Accounting fraud detection: Is it possible to quantify undiscovered cases? Working paper, Universidade Federal de Santa Catarina, Brazil.

## 12. Webgrafía

- Blodget H 2011. *China stock fraud shocker: Banks Were Complicit In Longtop Fraud*. En: Business Insider [sitio web] 25 may. 2011. [Consulta: diciembre 2017]. Disponible en:  
<http://www.businessinsider.com/china-stock-fraud-longtop-banks-complicit-2011-5>
- De la Merced MJ, Phillips M 2018. *Trump Asks S.E.C. to Study Quarterly Earnings Requirements for Public Firms*. En: New York Times [sitio web] 17 ago. 2018. [Consulta: agosto 2018]. Disponible en:  
<https://www.nytimes.com/2018/08/17/business/dealbook/trump-quarterly-earnings.html>
- Ng A 2017. *Machine Learning*. En: Coursera [sitio web]. EEUU: Stanford University. [Consulta: noviembre 2017]. Disponible en:  
<https://www.coursera.org/learn/machine-learning>
- Placer D 2017. *El juez Pedraz recupera el dinero de Gowex con cuentagotas*. En: EDeconomiadigital. [Sitio web]. 12 abr. 2017 [Consulta: diciembre 2017]. Disponible en:  
[https://www.economiadigital.es/directivos-y-empresas/el-juez-pedraz-recupera-el-dinero-de-gowex-con-cuentagotas\\_403560\\_102.html](https://www.economiadigital.es/directivos-y-empresas/el-juez-pedraz-recupera-el-dinero-de-gowex-con-cuentagotas_403560_102.html)
- Singh A, Xing E 2012. *Bias Variance Tradeoff and model selection*. CS 274A: *Probabilistic Learning: Theory and Algorithms*. En: UCI [sitio web]. EEUU: Donald Bren School of Information and Computer Sciences (UCI). [Consulta: enero 2018]. Disponible en:  
[http://www.ics.uci.edu/~smyth/courses/cs274/readings/xing\\_singh\\_CMU\\_bias\\_variance.pdf](http://www.ics.uci.edu/~smyth/courses/cs274/readings/xing_singh_CMU_bias_variance.pdf)
- *Sistema de Análisis de Balances Ibéricos (SABI)* [Base de datos online]. 2017. [Consulta: diciembre 2017]. Disponible mediante licencia:  
<https://sabi.bvdinfo.com/sso.aspx?path=rediris>