



## Facultad de Ciencias Económicas y Empresariales

Trabajo de  
fin de grado

### **Predicción de la quiebra empresarial: Un estudio empírico en la Eurozona**

**Miguel Arias Rodríguez**

Junio de 2025

# Resumen

El presente trabajo analiza la quiebra empresarial a través de una revisión de diferentes metodologías de predicción. El objetivo principal es desarrollar un modelo predictivo basado en datos reales de la Eurozona, considerando variables de fácil obtención como el tamaño, la liquidez, el endeudamiento e indicadores financieros.

Este trabajo presenta una revisión de la literatura académica relacionada, con especial atención a la posible traslación de los enfoques desarrollados en muestras de empresas de Estados Unidos para otras regiones. Tras la selección de la muestra y la definición de las metodologías, se realiza un análisis empírico, que evalúa la utilidad de distintos algoritmos para la predicción de la quiebra empresarial, tales como el modelo de regresión, las máquinas de vectores de soporte (SVM), las redes neuronales y los árboles de decisión. A partir de los resultados, se discuten sus fortalezas, limitaciones y se sugieren posibles líneas futuras de investigación.

Número total de palabras del trabajo: 9.993

# Índice

<b>Resumen.....</b>	<b>2</b>
<b>Índice de abreviaturas y definiciones .....</b>	<b>4</b>
<b>Índice de tablas, figuras y ecuaciones .....</b>	<b>5</b>
<b>Introducción .....</b>	<b>6</b>
<b>Desarrollo del trabajo .....</b>	<b>7</b>
2 Fundamentos teóricos y revisión de la literatura .....	7
2.1 Definiciones y marco conceptual del fracaso empresarial.....	7
2.2 Principales metodologías de predicción del fracaso.....	9
2.3 Variables explicativas más relevantes .....	12
2.4 Mercados, periodos y diferencias.....	16
2.5 Carencias en la literatura actual .....	18
3 Análisis empírico .....	21
3.1 Muestra y variables seleccionadas.....	21
3.2 Análisis descriptivo .....	24
3.3 Presentación de algoritmos y modelos utilizados .....	27
3.4 Entrenamiento de los modelos y resultados .....	27
<b>Conclusiones .....</b>	<b>31</b>
<b>Bibliografía.....</b>	<b>33</b>

# Índice de abreviaturas y definiciones

**ANN** – Artificial Neural Networks (Redes Neuronales Artificiales)

**Capital de Trabajo** –Fondo de Maniobra (Activo corriente – Pasivo corriente)

**INE**- Instituto Nacional de Estadística

**LASSO** – Least Absolute Shrinkage and Selection Operator (Operador de selección y contracción mínima absoluta)

**ML** – Machine Learning (Aprendizaje Automático)

**RAE** – Real Academia Española

**SEPE**- Servicio Público de Empleo Estatal

**SVM** – Support Vector Machine (Máquina de Vectores de Soporte)

**TRLC**- Texto Refundido de la Ley Concursal

**Variables Dummies** – Variable artificial con valores 1 o 0. Se puede usar para introducir efectos anuales en los modelos

# Índice de tablas, figuras y ecuaciones

<b>Ecuación 1:</b> Fórmula original del Altman Z-Score.....	10
<b>Ecuación 2:</b> Altman Zscore de empresas no manufactureras.....	27
<b>Figura 1:</b> Relación entre el tipo de interés de las operaciones principales (MRO) y quiebras en Europa (2000 – 2024).....	15
<b>Figura 2:</b> Evolución anual del número de empresas en quiebra contable (2015 – 2024).....	23
<b>Figura 3:</b> Quiebras contables anuales expresadas en términos porcentuales (2015 - 2024).....	24
<b>Figuras 4, 5, 6 y 7:</b> Distribución empírica de las variables explicativas clave empleadas en el modelo predictivo.....	25
<b>Figura 8:</b> Comparativa visual del desempeño de los distintos modelos.....	30
<b>Tabla 1:</b> Variables más relevantes a partir de selección LASSO.....	21
<b>Tabla 2:</b> Estadísticos descriptivos de las variables explicativas del modelo predictivo LASSO.....	25
<b>Tabla 3:</b> Comparativa de métricas de capacidad predictiva de los modelos de quiebra empresarial.....	29

# Introducción

El fracaso empresarial es un fenómeno que trasciende con mucho la contabilidad, pues detrás de una quiebra existe un conjunto de actores afectados. Así, tras una quiebra pueden existir trabajadores despedidos, inversores que asumen pérdidas, y un entorno (los llamados *stakeholders*) que también padecen las consecuencias. Aunque este fenómeno pueda parecer algo atípico, es habitual y forma parte de la propia dinámica empresarial: en España, por ejemplo, la crisis provocada por la COVID-19 supuso el cierre de más de 311.000 empresas (INE, 2021) y dejó a más de medio millón de personas sin trabajo en 2020 (SEPE, 2021).

Si bien es cierto que podría resultar imposible evitar por completo este tipo de situaciones al ser inherentes a la propia actividad económica, si fuésemos capaces de anticipar mejor cuándo pueden producirse, podríamos, al menos, reducir en parte su impacto negativo y sus consecuencias sobre la sociedad.

Cabe decir que el estudio de la quiebra empresarial, a través del análisis de sus factores determinantes y su posible predicción no es un campo nuevo. En Estados Unidos el estudio de metodologías de predicción de quiebras lleva desarrollándose décadas, con modelos como el Z-Score de Altman (1968) o el O-Score de Ohlson (1980), que han sido ampliamente utilizados. Ahora bien, aplicar directamente estos modelos en empresas europeas no siempre resulta acertado dado que existen diferencias claras en aspectos fundamentales, tales como el tamaño medio de las empresas, la legislación e incluso la propia estructura de su gobierno corporativo, que pueden afectar a los resultados. Por eso, en este trabajo se plantea el enfoque de analizar cómo funcionan diferentes algoritmos y compararlos con los métodos tradicionales existentes, pero aplicados en el contexto europeo.

El objetivo de este trabajo es evaluar la capacidad de diferentes modelos para predecir la quiebra empresarial y ver si ofrecer un análisis de posibles áreas de mejora frente a los enfoques clásicos, además de comprobar si lo que se ha utilizado en Estados Unidos puede trasladarse al Viejo Continente. El estudio se organiza en cuatro apartados: tras esta introducción, en el segundo apartado se presenta el marco teórico y los antecedentes; posteriormente, en el apartado tercero se realiza un análisis empírico con datos reales; y finalmente, en el cuarto y último apartado se sintetizan las principales conclusiones.

# Desarrollo del trabajo

## 2 Fundamentos teóricos y revisión de la literatura

### 2.1 Definiciones y marco conceptual del fracaso empresarial

Definir la quiebra o el fracaso empresarial es algo mucho más complejo de lo que a priori puede parecer: si nos atenemos a la ley española, en el artículo segundo del texto refundido de la Ley Concursal, segundo apartado, se recoge: “La insolvencia podrá ser actual o inminente. Se encuentra en estado de insolvencia actual el deudor que no puede cumplir regularmente sus obligaciones exigibles. Se encuentra en estado de insolvencia inminente el deudor que prevea que dentro de los tres meses siguientes no podrá cumplir regular y puntualmente sus obligaciones” (TRLR, 2020). Cobra de esta forma mucha importancia el término insolvencia, definido como la “incapacidad para pagar una deuda” (RAE, s.f.)

En esta misma línea, Beaver hacía hincapié ya en los años sesenta que el *failure* o fracaso era la incapacidad para hacer frente a las obligaciones financieras llegado el vencimiento (Beaver, 1966). Otros autores también usaron el término quiebra en un sentido aún más amplio, pero realizaron sus estudios con una muestra de empresas que se habían visto sometidas a una quiebra legal declarada, es decir, al proceso de bancarrota formal conforme a la legislación existente, que en el caso norteamericano era el *Chapter X*, vigente por aquel entonces (Altman, 1968).

Tanto en el propio estudio de Altman mencionado como en el de Ohlson y otros se diferencia, aunque no de forma explícita, entre insolvencia financiera (entendida esta como la incapacidad de pagar en el corto plazo, algo que medían las variables contables de su regresión) y la propia quiebra (liquidación y reorganización judicial), dejando entrever que la primera suele preceder a la segunda (Ohlson, 1980). La idea de ambos autores es que la quiebra no es repentina, sino que suele venir anunciada por débiles signos financieros previos, motivo por el que introdujeron variables contables en sus análisis. Ello tendría su lógica, no solo por el propio impacto directo de de estas variables, sino porque en última instancia reflejarían el conjunto de aspectos, externos e internos, que afectarían a la empresa.

Es importante señalar que no existe un consenso absoluto sobre una única definición de fracaso: para algunos autores, se engloban dentro del término diferentes estados de dificultad financiera, desde el mero *distress* (entendido en castellano como un tensionamiento financiero) hasta la quiebra propiamente dicha. En ese sentido, es relevante apuntar que la literatura utiliza diferentes términos como *financial distress*, *default* o *bankruptcy*, teniendo significados específicos. En este trabajo, se adopta una visión amplia del concepto, abarcando el término de fracaso empresarial tanto la propia insolvencia consumada (*default*) como la quiebra jurídica, implicando esta última la salida del mercado de la empresa por incapacidad financiera.

En lo que se refiere al marco conceptual, cabe señalar que las primeras investigaciones carecían de un soporte teórico consolidado y se centraron en enfoques empíricos (Beaver, 1966; Altman, 1968). Con el paso de los años, diversos estudios han buscado contribuir con la construcción de bases teóricas que fuesen capaces de explicar el porqué de la quiebra de unas empresas y la supervivencia de otras: De Llano, Piñeiro y Rodríguez (2016) destacan en un reciente estudio la ausencia de una teoría unificada de fracaso financiero y buscan “consolidar las bases de una teoría del fallo financiero” a través de la síntesis de hallazgos previos. La conclusión alcanzada por estos autores es la de que el fracaso empresarial puede ser entendido desde la teoría financiera combinando elementos de rentabilidad insuficiente, estructura de capital desequilibrada y problemas de liquidez, entre otros factores (de Llano et al., 2016).

En lo que respecta a las contribuciones de la teoría financiera clásica, cabe decir que esta aporta varios enfoques significativos: uno de ellos es la hipótesis de la estructura de capital óptima o teoría del *trade-off* (Kraus y Litzenberger, 1973), de la que se extrae que, si bien el endeudamiento es beneficioso en términos fiscales, también aumenta el riesgo de insolvencia de la firma si es excesivo. Otro ejemplo es la teoría de la agencia, que pone el foco en los problemas de gobierno corporativo y los conflictos de interés como una fuente de posibles decisiones subóptimas que precipitan el fracaso (Jensen y Meckling, 1976).

Otra contribución interesante y presente en algunos estudios la introducción de las perspectivas macroeconómicas: periodos de recesión y crisis financieras tienden a elevar las tasas de fracaso empresarial, poniendo de manifiesto la importancia del entorno. Podemos mencionar, en la línea de esta afirmación, que hay estudios que usan la tasa de crecimiento en términos reales del PIB como una variable significativa de cara a anticipar dificultades financieras de las compañías (Charalambakis y Garrett, 2018).

En lo que se refiere al marco temporal de las quiebras, cabe decir que abundan en la literatura los ejemplos de autores que lo consideran un proceso continuo: en esta línea encontramos a Laitinen que, a diferencia de los enfoques estáticos

(que comparan empresas quebradas y no quebradas en un momento dado), realiza un análisis de la evolución de las ratios en los años previos al colapso. A raíz de ese análisis, distingue entre empresas crónicamente frágiles (que tienen valores de riesgo muchos años antes de quebrar), aquellas que tienen problemas de financiación por ingresos (que tienen un deterioro progresivo) y las empresas con fracaso agudo, que mantienen ratios aceptables y el último año sufren un colapso abrupto (Laitinen, 1991).

A la luz de todo lo anterior, se puede afirmar que el fracaso empresarial se enmarca conceptualmente como un fenómeno multidimensional que se ve afectado por factores financieros (rentabilidad, liquidez o solvencia), no financieros (gobierno corporativo y conflictos de interés entre otros) y factores externos a la empresa (entorno macroeconómico y sectorial). La literatura ha evolucionado mucho en las últimas décadas, al pasar de modelos puramente empíricos a la construcción de teorías que integran múltiples definiciones y modelos, pero persisten las fragmentaciones en los enfoques y las definiciones al tiempo que la literatura para contextos específicos como la Eurozona es mucho menos abundante que los estudios de corte nacional.

## 2.2 Principales metodologías de predicción del fracaso

Como se puede inferir del apartado anterior, la literatura acerca de la predicción del fracaso ha ido evolucionando de forma sustancial en los últimos años. En este sentido, es importante apuntar que existe una amplia gama de metodologías diferentes, pero todas ellas se pueden segmentar en grandes bloques que recogen las distintas generaciones y las características principales de las mismas:

- 1) Análisis univariante de ratios: Podría afirmarse que esta metodología fue la pionera en el ámbito de predicción del fracaso. En ella destacó la aproximación univariante de Beaver, que analizó la capacidad predictiva de indicadores financieros individuales para distinguir entre empresas fracasadas y no fracasadas. En su estudio, llegó a la conclusión de que ciertas ratios (menciona en particular la de flujo de caja en relación con la deuda total) presentaban significativas diferencias años antes de la quiebra (Beaver, 1966). Se trataba de un primer paso efectivo, pero este enfoque de una única variable se vio superado rápidamente por modelos más sofisticados.
- 2) Modelos multivariantes lineales: En las décadas de 1960 a 1980 hubo importantes avances en el campo del estudio de las quiebras: sería durante estos años cuando Altman presentó su técnica de análisis discriminante múltiple. Precisamente nació aquí el famoso modelo Z-Score, que

combinaba cinco ratios financieras en una función lineal para clasificar las empresas en dos grupos: sanas y en quiebra. Con este método, logró unas tasas de acierto superiores a las del análisis univariante (Altman, 1968). El éxito académico que alcanzó su artículo popularizó este tipo de modelos; posteriormente, Ohlson introdujo la regresión logística (*logit*) para predicción de quiebras, un enfoque probabilístico que no requería supuestos tan estrictos como el discriminante y que permitía estimar directamente la probabilidad de quiebra en términos de tanto por uno (Ohlson, 1980). Resulta elocuente decir que ambas metodologías se toman frecuentemente como punto de comparación con nuevos métodos predictivos en muchos estudios actuales para sacar conclusiones sobre la utilidad de estos; por ejemplo, en los de Jones y Barboza (Jones et al., 2017; Barboza et al., 2017).

Ecuación 1: Fórmula original del Altman Z-Score

$$Z = 0.012X_1 + 0.014X_2 + 0.033X_3 + 0.006X_4 + 0.999X_5$$

$$X_1 = \frac{\textit{Working capital}}{\textit{Total assets}}$$

$$X_2 = \frac{\textit{Retained Earnings}}{\textit{Total assets}}$$

$$X_3 = \frac{\textit{Earnings before interest and taxes}}{\textit{Total assets}}$$

$$X_4 = \frac{\textit{Market value equity}}{\textit{Book value of total debt}}$$

$$X_5 = \frac{\textit{Sales}}{\textit{Total assets}}$$

$$Z = \textit{Overall index}$$

Fuente: Elaboración propia a partir de Altman (1968)

- 3) Modelos de duración y hazard: Entre la década de los noventa y principios de siglo, surge una nueva generación de modelos más complejos que buscan introducir el elemento temporal (la idea de que el riesgo de quiebra varía con el tiempo). Reciben el nombre de modelos de duración o *survival*, y se caracterizan por modelar la probabilidad de un evento, pero condicionándola

a que no haya ocurrido tal evento antes o a un momento temporal determinado. En esta corriente, destacan autores como Shumway, que propuso un modelo de riesgo *hazard* que permitía corregir los sesgos de selección de los modelos logit estáticos, mejorando la estimación de la probabilidad de quiebra con datos de panel (Shumway, 2001). En modelos más recientes, podemos destacar a Tian y Yu, quienes aplican un modelo *hazard* discreto con datos de panel de múltiples países y lo combinan con técnicas de selección de variables LASSO (*least absolute shrinkage and selection operator*) (Tian y Yu, 2017). Por último, Charalambakis y Garrett utilizan un enfoque *logit* multiperiodo para evaluar la persistencia predictiva a distintos plazos, llegando a la conclusión de que su modelo mantiene capacidad predictiva tanto a corto como a largo plazo (Charalambakis y Garrett, 2018).

- 4) Modelos basados en Inteligencia Artificial y *Machine Learning*: A finales del siglo XX, con la innovación en la computación y el aumento de la capacidad de procesamiento de datos, comienzan a popularizarse las técnicas de inteligencia artificial para el proceso de predicción de quiebras. Ya en los últimos años de la década de los ochenta e inicios de los noventa surgen aplicaciones de redes neuronales artificiales (*Neural Network*) con el objetivo de buscar relaciones no apreciables a simple vista por medio de la *generalización* (permite aplicar lo aprendido a nuevos datos no vistos en el entrenamiento del sistema). Después de aplicar esta metodología, algunos autores concluyeron que su sistema era más efectivo que el tradicional *análisis discriminante* en muestras reducidas (Odom y Sharda, 1990). Será en esta época cuando se comiencen a utilizar también técnicas como los árboles de decisión y los métodos basados en reglas difusas (*rough sets*). Ya en el nuevo siglo, surgen investigaciones con algoritmos como las *Máquinas de vectores de Soporte* (SVM) y los *modelos de ensamble*. Es el caso del estudio de Barboza et al., que, como ya se mencionó, comparan distintos métodos de machine learning (*árboles, bosques aleatorios, boosting o SVM*) contra técnicas tradicionales sobre una muestra de empresas estadounidenses con datos de 1985 a 2013, concluyendo que “los modelos de ML muestran, de media, aproximadamente un 10% más de precisión que los modelos tradicionales” (Barboza et al., 2017). Cabe cerrar este apartado apuntando que otros estudios de estos años como en el ya mencionado de Jones et al. (2017) aportan conclusiones similares, afirmando que estos modelos “predicen significativamente mejor que todos los demás clasificadores”.
- 5) Métodos híbridos y Aprendizaje Profundo (*Deep Learning*): En la época actual, la investigación se caracteriza por utilizar técnicas muy sofisticadas que combinan algunos de los modelos anteriores. A estas técnicas se las

denomina modelos híbridos, y en ocasiones utilizan metodologías de distintas generaciones (redes neuronales con análisis discriminante, por ejemplo). En los últimos años, cabe apuntar que también existen estudios que han aplicado el *Deep Learning* como herramienta de análisis de datos textuales. Mai et al. (2019) aplican estos modelos a textos de divulgaciones corporativas tales como memorias e informes varios con el objetivo de predecir quiebras, llegando a la conclusión de que “usar simultáneamente inputs textuales y numéricos ha mejorado la precisión sobre la de los modelos que usan un único input”.

En suma, cabe decir que las metodologías de predicción del fracaso han evolucionado desde modelos estadísticos simples como el *logit* o el discriminante a complejos enfoques basados en la inteligencia artificial. Cada uno de ellos tiene sus puntos fuertes y débiles: los enfoques tradicionales ofrecen sencillez, comparabilidad y fácil interpretación del porqué de los resultados (al conocer los pesos de las variables), mientras que los más modernos de *ML* pueden captar relaciones complejas y procesar con rapidez grandes volúmenes de datos e información, pero no es posible en muchos casos entender cómo se llega a las conclusiones, lo que puede dar lugar a problemas graves (Rudin, 2019). Por ello, buena parte de la literatura actual hace hincapié en la necesidad de buscar enfoques que sean a la vez interpretables y de alto rendimiento, motivo por el que la selección de variables de la que se hablará en el siguiente apartado es de gran importancia.

### 2.3 Variables explicativas más relevantes

Si nos retrotraemos al inicio de la investigación sobre quiebras, los estudios clásicos tenían un marcado corte empírico en el que se empleaban ratios contables sencillos como variables explicativas con el fin de anticipar estos fenómenos. En las últimas décadas, la inteligencia artificial ha subido muchos enteros en el ámbito académico, si bien en esencia es el mismo sistema: la cantidad de datos que se analizan es muy superior, pero hasta los modelos más complejos de *ML* (como las redes neuronales profundas) parten de un conjunto de variables explicativas. Así, queda patente que la correcta selección de estas es crucial para el desarrollo de un sistema efectivo. A la luz de la revisión de la literatura, se pueden mencionar como variables relevantes las que siguen:

- **Ratios financieras clásicas:** Son muy numerosos los estudios que afirman que un conjunto reducido de ratios resume gran parte del riesgo de fracaso. De Llano et al. (2016) afirman que “cualquiera que sea la metodología, se pueden emitir predicciones fiables usando cuatro variables (...) de rentabilidad, estructura financiera, rotación y flujos de caja”. Otros autores sugieren que solo con tres ratios financieras se pueden lograr modelos de alta precisión

predictiva en mercados como Japón, si bien existe cierta variabilidad sobre qué variables emplear en función del país (Tian y Yu, 2017). Entre los indicadores más relevantes están:

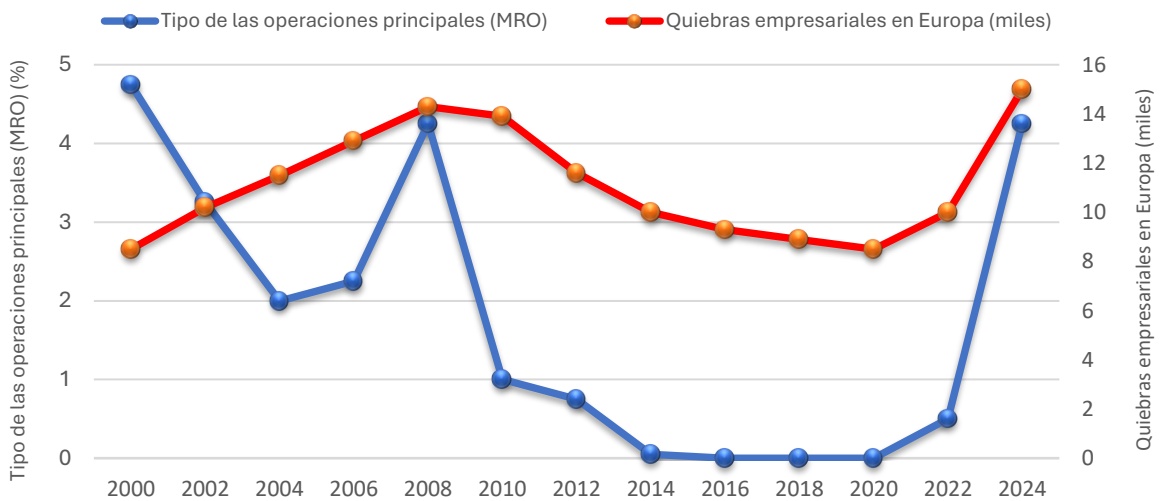
1. Rentabilidad: Es una medida del rendimiento que obtiene la empresa con los recursos de que dispone. Se mide generalmente por el ROA (Retorno sobre Activos) o margen neto. El menor rendimiento de los activos es un presagio de posibles dificultades financieras (Campbell et al, 2008). Otros autores pioneros incluían también medidas como la rentabilidad de activos por medio de la ratio EBIT/Activo (Altman, 1968) o Ingresos Netos/Patrimonio (Beaver, 1966).
  2. Liquidez: Mide la capacidad de una empresa para atender a sus obligaciones a corto plazo. En este apartado cabe mencionar al *current ratio* (activo corriente/pasivo corriente) o capital de trabajo/Activo (Altman, 1968), ratios que suelen ser significativos y donde la menor liquidez se asocia con mayor riesgo.
  3. Apalancamiento y solvencia: En esta categoría se encuentran indicadores de endeudamiento tales como deuda total/activos o deuda/recursos propios, que aparecen de forma recurrente asociados al fracaso (endeudamiento excesivo implica mayores probabilidades de quiebra). En esta línea, hay estudios que apuntan que la ratio Deuda Total/Activos Totales resultaba muy consistente en el caso del mercado japonés (Tian y Yu, 2017).
  4. Actividad o eficiencia operativa: Existen métricas como la rotación de activos (Ventas/Activos) o la rotación de inventarios cuyo descenso señala en ocasiones problemas de gestión y dificultades en el mercado que pueden preceder al fracaso. De Llano et al. (2016) introducen una variable de rotación entre las cuatro que consideran suficientes para hacer predicciones fiables.
  5. Flujo de Caja: La última categoría de las ratios financieras tradicionales comprende métricas como el flujo de caja operativo/deuda o la ratio de cobertura de intereses, medidas que representan la capacidad de la empresa para hacer frente a sus obligaciones. En línea con esto, el pionero estudio de Beaver concluía que la ratio Flujo de Caja/Deuda Total era un indicador excelente con poder discriminador en el periodo de 5 años (Beaver, 1966)
- Variables de mercado y valor bursátil: En el caso de las firmas cotizadas, cabe apuntar que la información procedente del mercado nos aporta información adicional muy relevante. Estudios como el de Campbell et al. afirman que

“acciones con alto riesgo de fracaso tienden a presentar rentabilidades anormalmente bajas” (Campbell et al., 2008). Las variables de mercado (precio de las acciones o primas de opciones, entre otras) resultan útiles desde el punto de vista de que ofrecen la valoración colectiva que se hace de un negocio con menor lapso temporal que la contabilidad (por ejemplo, si el precio de unas acciones cae de forma muy significativa, puede indicar que se empieza a valorar la posibilidad de quiebra). Relacionado con esto, Merton diseña un modelo sobre cómo el precio de la deuda corporativa refleja también las expectativas sobre la firma. Para ello, toma como una de las variables la probabilidad de impago en la valoración, afirmando que “la diferencia de precios entre bonos (los de la propia empresa y los libres de riesgo) se deben únicamente a diferencias en la probabilidad de impago”, bajo el supuesto de una estructura temporal de tipos constante (Merton, 1974).

- Estructura del capital y reservas acumuladas: Muchos estudios académicos hacen hincapié en la importancia de la estructura financiera interna de la empresa y la separan de las ratios financieras (aunque en esencia también lo son) dado que obedecen a decisiones de la dirección, tales como reinvertir beneficios o dar dividendos. Algunos indicadores de esta categoría aparecen en trabajos como el de Altman, que incluyó en su Z-Score la ratio Ganancias Retenidas/Activo, afirmando que ponía en desventaja a las empresas jóvenes: “la incidencia de fracaso es muy superior en los primeros años de una firma” (Altman, 1968).
- Variables relacionadas mercados exteriores y dividendos: Algunos estudios recientes han señalado factores como la política de dividendos o la internacionalización de la empresa. En esta línea, Charalambakis y Garrett encuentran en un estudio sobre empresas griegas que el pago de dividendos y el peso de las exportaciones están asociados negativamente con la probabilidad de que una firma privada quebrase (Charalamabakis y Garrett, 2018). Resulta bastante intuitivo en términos económicos: exportar indica que una empresa es competitiva a nivel internacional y pagar dividendos, que hay confianza en los flujos de caja futuros.
- Indicadores macroeconómicos: Cabe decir que, si bien la mayoría de los modelos son a nivel micro (firma), también se han incorporado variables macro en algunos para reflejar en entorno. Así, en un estudio sobre empresas griegas se introdujo el crecimiento del PIB real como variable en un estudio multiperiodo, encontrándolo significativo: una economía en crecimiento tiene menor riesgo de *distress* corporativo (Charalambakis y Garrett, 2018). De esta forma, en contextos con ciclos económicos distintos es recomendable introducir variables *dummies* para periodos de crisis (gran recesión o Covid-19), ya que pueden ayudar a capturar riesgos sistémicos. En

la gráfica de abajo, se muestra la evolución anual del tipo de las operaciones principales del BCE y el número de quiebras empresariales en Europa (en miles) entre 2000 y 2024. Se observa que los incrementos sostenidos en los tipos de interés suelen preceder aumentos significativos en las quiebras empresariales, especialmente tras 2008 y a partir de 2022, mientras que los periodos de tipos bajos se asocian con una reducción progresiva de insolvencias.

Figura 1: Relación entre el tipo de interés de las operaciones principales (MRO) y quiebras en Europa (2000 – 2024)



Fuente: Elaboración propia a partir de datos del BCE (2025) y de datos de Eurostat (series históricas y sts\_rb\_q).

- **Métricas de gobierno corporativo y gestión:** Resultan valiosas, especialmente en las empresas de menor tamaño y no cotizadas. Estudios como el de Ciampi han investigado específicamente el aporte de la gestión a modelos de default en empresas italianas. Las conclusiones que alcanzó fueron que, en pequeñas empresas, factores como la concentración de la propiedad y la dualidad CEO-presidente en el mismo mando estaban relacionados con menor riesgo de fracaso (Ciampi, 2015).
- **Indicadores de calidad contable y fraude:** Esta rama es más reciente que la anteriores, y en ella se busca estudiar si las prácticas contables agresivas y las anomalías en los estados financieros anteceden a quiebras. En el estudio de Serrano-Cinca et al. (2019), aplican sobre una muestra de más de 50,000 empresas ratios diseñadas para detectar depreciaciones anómalas, cuentas por cobrar infladas y otras figuras equivalentes, llegando a la conclusión de que "las ratios financieras clásicas son mejores para compañías cotizadas que para firmas privadas (no cotizadas), mientras que las variables que detectan anomalías contables son especialmente útiles para firmas privadas".

- Otras variables no financieras: Se pueden introducir en esta categoría variables como la antigüedad de la empresa, su estructura legal, la pertenencia a conglomerados o incluso medidas de capital humano. Muchas de ellas no han demostrado ser significativas en la práctica; en este subapartado, la idea que se busca resaltar es que hay muchas variables que se pueden considerar y que la literatura aún no ha estudiado, pero que no por ello no tienen que ser malos predictores potenciales del fracaso empresarial.

Para cerrar este apartado, ha quedado patente que en grandes empresas cotizadas las ratios financieras tradicionales de liquidez, rentabilidad, apalancamiento y eficiencia proporcionan grandes resultados en la labor de predecir el fracaso. Pero la existencia de miles de estructuras y tamaños de empresas diferenciados ha llevado a buscar indicadores que se ajusten mejor a la realidad de las PYMES, introduciendo algunas de las variables que se han mencionado. Asimismo, distintos mercados y periodos históricos requieren en muchas ocasiones ajustes en los modelos: de esto se hablará en el apartado siguiente.

## 2.4 Mercados, periodos y diferencias

Los distintos modelos de predicción del fracaso han sido probados en contextos y periodos variados. Hacer un análisis de las diferencias entre dichos modelos permite ver hasta qué punto los mercados (y las empresas que los componen) cambian entre si y con el tiempo. El objetivo es detectar diferencias nacionales y temporales en la literatura existente y ver si se pueden “generalizar” los sistemas, buscando que sean utilizables en múltiples contextos.

Como ya se ha mencionado, tradicionalmente los estudios de quiebras clásicos se concentraron en Estados Unidos. En ellos, se aprovechaba la abundancia de datos de empresas cotizadas y de información sobre firmas quebradas (Altman, 1968; Ohlson, 1980). El resultado: modelos muy adaptados a las características de las firmas norteamericanas. La investigación académica en Europa sobre esta temática explotó con el comienzo del nuevo siglo, gracias a bases de datos de países europeos, como es el caso en España de Sabi. Dicho esto, la mayoría de trabajos se enfocaron en países individuales: Italia (Ciampi, 2015), Grecia (Charalambakis y Garrett, 2018) o Polonia (Zięba et al., 2016). La dificultad principal es que en cada mercado europeo existen legislaciones concursales distintas, culturas empresariales diferenciadas y otros factores que hacen muy complicado el hacer estudios que resulten comparables entre todos los países.

En lo que respecta a mercados emergentes y países en desarrollo, la literatura es muy escasa en algunos casos y prácticamente inexistente en otros: en África,

prácticamente no hay estudios, y en América Latina se pueden encontrar algunos esfuerzos en países como Brasil, Chile o México. En China, el significativo desarrollo económico de los últimos años ha llevado a una explosión en los estudios de quiebras, promovidas también por el gobierno con el fin de reducir el riesgo sistémico. Es por ello que se hicieron estudios referidos a sectores estratégicos concretos, como es el caso de la industria hotelera (Sun et al. 2014). En líneas generales, se puede decir que los estudios de quiebras están más extendidos en países con economías desarrolladas y economías asiáticas avanzadas.

En lo que respecta a los periodos temporales estudiados, cabe decir que los estudios también varían ampliamente: los modelos clásicos están entrenados con datos de las décadas de 1960 a 1980, como en el caso de Altman (1968) y Ohlson (1980). Surge ante esta tesis la duda acerca de la estabilidad temporal de los modelos: ¿son los datos de hace más de medio siglo útiles en el contexto actual? La evidencia empírica indica que la precisión tiende a perderse si no se actualizan los modelos, debido a cambios estructurales en la economía (por ejemplo, el creciente peso del sector tecnológico) y a prácticas contables diferentes (variaciones en las normas de información financiera, como el Plan General Contable).

En lo que respecta a los ciclos económicos, cabe decir que existen estudios que examinaron la precisión de los modelos durante recesiones en relación con periodos “normales”, llegando a la conclusión de que “el declive económico coincide con el deterioro de la capacidad de los modelos” (Pompe y Bilderbeek, 2005). De esta forma, se puede afirmar que los modelos entrenados en épocas de bonanza tienden a sobreestimar la salud de las empresas durante las recesiones, y viceversa. En línea con lo anterior, cabe decir que crisis económicas como la *Gran Recesión* de los años 2008 y 2009 supusieron puntos de inflexión. En este sentido, muchas investigaciones han separado muestras pre y postcrisis para recalibrar sus modelos, y han tenido que hacer ajustes en ellos al reflejar las empresas en su conjunto nuevos comportamientos en cuanto a la deuda y liquidez.

Más cercano e igual de caótico es el ejemplo de la pandemia del COVID-19 en 2020, que provocó aumentos significativos de riesgos de insolvencia e inviabilidad (Banco de España, 2021). De todas formas, es importante apuntar que los eventos extremos, llamados *cisnes negros* en el argot financiero, siguen suponiendo un desafío muy grande incluso para los modelos más avanzados de *Machine Learning*, dado que, al ser entrenados mayormente con datos de periodos estables, no anticipan adecuadamente estos eventos extraordinarios (López de Prado, 2018).

Así, los principales problemas que se encuentran en relación con los mercados son las diferentes legislaciones nacionales y la carencia de estudios en algunas

áreas geográficas. Por otro lado, en lo que se refiere a los períodos, las dificultades van en la línea de las variaciones en la legislación concursal y contable y la propia existencia de ciclos económicos correctivos con fuertes recesiones. Todo ello genera cambios de paradigma y dificulta la aplicación *in aeternum* de los mismos métodos y métricas. A todo lo anterior hay que sumar la existencia de *gaps* en la literatura actual, al existir áreas y cuestiones relevantes que prácticamente no se han estudiado ni introducido en los modelos, algo de lo que se hablará en el siguiente apartado.

## 2.5 Carencias en la literatura actual

Para cerrar este apartado de revisión de la literatura, resulta conveniente hacer hincapié en algunas de las principales debilidades que se pueden encontrar al estudiar de forma exhaustiva qué se ha hecho hasta hoy. Algunas de ellas son especialmente visibles en el caso del mercado europeo:

- Carencia de estudios integrales en la Eurozona: A pesar de que los estudios de países europeos individuales son muy abundantes en el Viejo Continente, no existen prácticamente estudios que abarquen simultáneamente la Eurozona como un todo, aún cuando ya hace más de un cuarto de siglo que se adaptó la moneda común. Un estudio de estas características permitiría evaluar si la integración en un mercado y la existencia de una moneda compartida permiten que un mismo sistema sea efectivo en contextos nacionales tan diferenciados o si persisten peculiaridades nacionales que hacen que hay que individualizar el análisis. Existen, no obstante, estudios que utilizan datos de empresas europeas de países como Alemania, Francia, Reino Unido o Dinamarca (Korol, 2019), pero no todos esos países comparten moneda.
- Escasa integración de factores macroeconómicos y coyunturales en los modelos: La mayoría de los modelos se centran en variables a nivel firma, y asumen que los efectos macro son comunes a todos los países. Esta suposición es fácilmente criticable (especialmente en el contexto europeo) por la existencia de *shocks asimétricos* y políticas fiscales individualizadas que pueden dar lugar a diferencias muy significativas en las tasas de fracaso empresarial. El estudio de variables macroeconómicas en la literatura es muy escaso, pudiendo destacar a Charalambakis y Garrett (2019) que introducen el crecimiento real del PIB como una variable relevante para las firmas griegas. El estudio de la política fiscal nacional es aún más escaso y resulta también interesante, puesto que hay trabajos que sugieren que existe una fuerte competencia fiscal entre países (Overesch y Rincke, 2011). Estudiar hasta qué punto la política fiscal influye en la atracción de inversiones a un país y, en última instancia, en la competitividad (y solvencia) de sus empresas resulta interesante para la investigación sobre quiebras.

- Falta de consenso sobre la superioridad de metodologías avanzadas: Son muchos los estudios que concluyen que, en términos de capacidad predictiva, los modelos basados en inteligencia artificial son superiores a los tradicionales: es el caso de estudios como Barboza et al. (2017) o Zięba et al. (2016). Pero los modelos *black box* o de caja negra tienen un grave problema, y es que no sabemos el porqué de los resultados: “abrir la caja negra de una red neuronal podría arrojar luz sobre la naturaleza de las evidencias que conducen a quiebras futuras” (Mai et al., 2019). Hoy por hoy, es claro que existe un evidente *tradeoff* entre la sencillez de un modelo, que nos permite menor capacidad predictiva, pero conocimiento de cómo afectan las variables seleccionadas, frente a otras formas de predicción más sofisticadas que, en general, nos dan mejores resultados, al tiempo que pueden cometer grandes errores en épocas de mucha volatilidad y cambio. La solución pasa por extraer lo mejor de cada modelo y utilizar el procesado de datos como una herramienta para volver más sofisticados los modelos de los que ya disponemos.
- Necesidad de incluir datos no financieros y alternativos: El mencionado artículo de Mai et al. (2019) del apartado anterior utiliza el texto de informes corporativos, y Serrano-Cinca et al. (2019) aplican indicadores de calidad contable, pero son una minoría en relación con la práctica totalidad de investigaciones en las que se usan ratios tradicionales. Resulta sorprendente que no se hayan introducido en la literatura fuentes de *Big Data* que pudiesen enriquecer la predicción, tales como información procedente de redes sociales, noticias o indicadores sectoriales en tiempo real. Otras herramientas, como *Google Trends*, pueden dar señales tempranas de cuando una empresa está perdiendo el interés del público. Integrar todos estos elementos puede ayudar a crear sistemas mucho más robustos y precisos.
- Pocos estudios en PYMES y empresas no cotizadas: Como ya ha quedado patente en este trabajo, las grandes empresas (especialmente las cotizadas) son en las que más se ha centrado la literatura. Los estudios específicos sobre las pequeñas y medianas señalan particularidades como la importancia de la gobernanza corporativa (Ciampi, 2015). En el caso el español, las empresas de menos de 250 asalariados dan empleo al 57% de los empleados (Ministerio de Industria y Turismo, 2025), de forma que son de vital importancia para el tejido productivo español. A mayores, resultan interesantes también a nivel macro, dado que al tener muchas de ellas estructuras financieras más débiles, ver la evolución en números de los cierres de estas empresas puede ser un interesante indicador adelantado al ciclo económico (y a potenciales quiebras de empresas más grandes, por efecto contagio).

- Diferencias de entornos legales y su impacto en las quiebras: junto con la importancia de la política fiscal, hay que subrayar que los modelos de predicción se ven afectados por diferencias legislativas en las leyes concursales: en algunos países, la quiebra es la entrada en *concurso de acreedores*, mientras que en otros es la liquidación. Todo ello tiene un impacto directo sobre los modelos, y hace que la probabilidad de quiebra no sea directamente comparable entre países. En el caso de la Eurozona, si bien se está tendiendo a la igualación de las legislaciones nacionales, cabe decir que quedan muchos pasos por dar: unificar la definición de fracaso es uno de ellos.
- Importancia de la estabilidad temporal y actualización de los modelos: En este punto, la crítica fundamental es que no existen “reglas escritas” acerca de cómo se han de recalibrar los modelos para mantenerlos actualizados con el tiempo. Esta problemática se aborda en artículos como el de Büchel et al. (2022) en el que se aplican Redes Neuronales Artificiales (ANNs) para llevar a cabo el ajuste, pero el problema está en que no hay consensos y la literatura es inexistente más allá de estudios individuales aislados.
- Problemas asociados a impactos sistémicos y contagios: Una de las cuestiones más recurrentes es que, los análisis suelen ser de empresas individuales (lo que no quita que se analicen muchas simultáneamente). Fenómenos como la Gran Recesión, la crisis del COVID-19 o, la guerra comercial entre Estados Unidos y China, ponen de manifiesto que existen fuertes interdependencias entre las empresas y la propia situación económica, estando expuestas a perturbaciones globales. La capacidad predictiva de los sistemas de *Machine Learning* frente a los *cisnes negros* es, por el momento, bastante reducida. Por ello, cabe decir que ahondar en el estudio de crisis y pánicos es de gran importancia para mejorar los modelos predictivos, al ser en esos momentos cuando tienen lugar muchas de las quiebras que se buscan predecir.

En conclusión, la revisión de la literatura revela que se ha avanzado mucho en los métodos y las variables empleadas, así como en la propia capacidad predictiva de los modelos. El *Machine learning* es la cara visible una nueva generación de modelos capaces de lograr analizar cantidades descomunales de datos, pero que presentan también problemas graves, como la opacidad de sus predicciones. Por último, hay que apuntar que resulta sorprendente que no haya muchos autores que introduzcan información de estilo de publicaciones en redes sociales o variables macro en sus análisis y que sorprende que sean tan escasos los estudios que analizan la Eurozona en su conjunto. Precisamente, para suplir esa carencia, en el siguiente apartado se realizará un estudio sobre ese mercado.

### 3 Análisis empírico

#### 3.1 Muestra y variables seleccionadas

La muestra empleada en este estudio procede de la base de datos financiera *Eikon*, y se compone de más de 3000 firmas no financieras cotizadas en la Eurozona de las que se han seleccionado 617 (al disponer de todos los datos contables en estas) y sus correspondientes observaciones en el periodo comprendido entre el año 2015 y 2024. Se utilizarán los datos correspondientes al periodo 2015 a 2019 para entrenar el modelo y del 2020 al 2024 para realizar las predicciones. Las variables que hemos utilizado para llevar a cabo el estudio proceden de la contabilidad. Si bien es cierto que en el apartado de *variables más relevantes* se mencionaban muchas otras, lo cierto es que los datos no están disponibles o son difíciles de obtener, de manera que hemos optado por realizar el estudio con algunas ratios clásicas (el signo + implica relación positiva con la probabilidad de quiebra y viceversa):

Tabla 1: Variables más relevantes a partir de selección LASSO

Variables	Label	Definición	Relación con quiebras	Dimensión económica
Apalancamiento dinámico	Liab_Growth <sub>t</sub>	$\frac{TOT\_LIAB_t - TOT\_LIAB_{t-1}}{TOT\_LIAB_{t-1}}$	+	Solvencia/Endeudamiento
Rentabilidad	$\Delta ROA_t$	$ROA_t - ROA_{t-1}$	-	Rentabilidad
Cobertura de intereses	$\Delta^2(Cov_t)$	$Cov_t - 2 \cdot Cov_{t-1} + Cov_{t-2}$	-	Liquidez/Cobertura financiera
Entorno macroeconómico	$\Delta(ECB\_10Y_t)$	$ECB\_10Y_t - ECB\_10Y_{t-1}$	+	Factores macro (tipos de interés)

Fuente: Elaboración propia a partir de datos de Eikon

En este modelo se ha introducido una diferencia fundamental con respecto a los modelos clásicos: el uso de derivadas y aceleraciones. Altman (1968) y Ohlson (1980) usan ratios contables puntuales y en algunos trabajos como el de Laitinen (1991) se incluyen variaciones anuales. La clave de este enfoque, y la nueva aportación está en la utilización de derivadas segundas (aceleración). La explicación del porqué se han seleccionado las variables anteriores es la siguiente:

$$\text{Minimizar} = -\log(\text{Verosimilitud}) + \lambda \sum_j |\beta_j|$$


La función mostrada corresponde a la regresión logística penalizada con método Lasso, utilizada en este trabajo para seleccionar automáticamente las variables financieras más relevantes a la hora de predecir la quiebra empresarial. Este procedimiento consiste en ajustar el modelo de forma que no solo busque la mejor capacidad de predicción, sino que también elimine aquellas variables que aportan poco o nada de información útil. Para ello, añade una penalización que fuerza a muchos coeficientes a ser exactamente cero, de modo que solo sobreviven en el modelo las ratios que realmente ayudan a anticipar el fracaso empresarial.

- $\text{Liab\_Growth}_t$  ( $\text{Pasivo total}_t - \text{Pasivo total}_{t-1}$ ) /  $\text{Pasivo total}_{t-1}$ : El crecimiento interanual del pasivo total actúa como una señal temprana de tensiones de solvencia, en línea con la hipótesis del trade-off de la estructura de capital. Un incremento rápido del endeudamiento suele preceder a situaciones de distress, a diferencia de las ratios de apalancamiento convencionales, que repintan y solo capturan el riesgo cuando la quiebra es inminente.
- $\Delta \text{ROA}_t$  ( $\text{ROA}_t - \text{ROA}_{t-1}$ ): La variación anual de la rentabilidad sobre activos capta el deterioro operativo estructural de la firma. Numerosos estudios (Beaver, Altman, Campbell) demuestran que una caída persistente en la rentabilidad es uno de los mejores predictores adelantados de default, superando en poder explicativo a los niveles absolutos de ROA.
- $\Delta^2(\text{Cov}_t)$  ( $\text{Cov}_t - 2 \cdot \text{Cov}_{t-1} + \text{Cov}_{t-2}$ ): La aceleración negativa en la cobertura de intereses (segunda derivada) permite detectar empeoramientos súbitos en la capacidad de la empresa para atender sus obligaciones financieras. Este tipo de variaciones rápidas es especialmente relevante en escenarios de subidas de tipos o estrés de mercado, donde el deterioro no es lineal sino abrupto.
- $\Delta(\text{ECB\_10Y}_t)$  ( $\text{ECB\_10Y}_t - \text{ECB\_10Y}_{t-1}$ ): La inclusión de una variable macroeconómica (variación en los tipos de interés a largo plazo) responde a la necesidad (detectada en la revisión de la literatura) de capturar shocks externos que afectan transversalmente a la viabilidad de las empresas. La subida de tipos incrementa el coste de financiación, agravando la fragilidad de empresas endeudadas y anticipando olas de quiebra, como evidencian tanto los episodios recientes en Europa como los análisis de Charalambakis y Garrett (2018).

En este estudio consideraremos fracaso las situaciones en las que el total de activos es menor al total de pasivos de una compañía, situación que se

denomina *quiebra técnica* en contabilidad y que recoge a aquellas empresas con patrimonio neto negativo, criterio frecuentemente utilizado para distinguir las firmas insolventes del resto (IMF, 2021). De acuerdo con esta descripción, satisfacen este criterio en el periodo estudiado las siguientes empresas:

Figura 2: Evolución anual del número de empresas en quiebra contable (2015 – 2024)




Fuente: Elaboración propia a partir de la muestra de datos de Eikon

Si tenemos en cuenta que la muestra comprende 617 empresas, los cálculos presentan una media del 2,17% de firmas en *quiebra técnica* en relación con el total cada año. Resulta conveniente realizar una apreciación: la cifra anterior es un *stock*, lo que quiere decir que la misma firma puede aparecer varios años hasta que deje de operar.

A mayores, es importante tener cautela a la hora de interpretar los resultados: muchas empresas quiebran antes de entrar en el terreno del patrimonio neto negativo por circunstancias como la pérdida de confianza del mercado, litigios o tensionamientos de caja que le impiden seguir operando. Asimismo, otras empresas con patrimonio neto negativo pueden sobrevivir muchos años si tienen flujo de caja operativo positivo y persiste su acceso a financiación. De acuerdo con datos de Eurostat, en torno al 8,7% de las empresas quiebran anualmente en Europa, cifra superior a la mostrada en este estudio, pero que obedece a lo que se acaba de explicar. Cabe añadir que las diferencias entre países son muy significativas, con Grecia, donde solo quebraron un 2% de empresas en 2022 y Estonia, donde la cifra alcanza el 25% (Eurostat, 2024). También cabe decir que cuando se habla de quiebras en números macro computa exactamente igual una sociedad con un único empleado que una macro corporación, aún cuando su impacto en la economía no es el mismo.

En cualquier caso, desde un punto de vista contable-legal, la definición del *negative equity* es la referencia, y funciona especialmente bien en las compañías medianas y grandes, dado que su contabilidad está mucho más regulada y que los mercados de bonos, CDSs y acciones reaccionan muy rápido a los deterioros en las cifras de las empresas. También es importante añadir que el aumento de empresas con *equity* negativo es una señal fiable de un empeoramiento de la situación empresarial, tal y como se puede apreciar en el gráfico de la parte inferior. El año 2016 puede resultar curioso para el lector, pero se produjeron dos eventos muy relevantes: el *referéndum* del Brexit y endurecimiento de la política del BCE en sus programas de *Quantitative Easing* que impactó a las empresas zombies. En el año 2020 se produjo la pandemia del Covid-19 y la salida efectiva del Reino Unido de la Unión Europea, lo que impactó de lleno a la mayoría de las economías europeas.

Figura 3: Quiebras contables anuales expresadas en términos porcentuales



Fuente: Elaboración propia a partir de la muestra de datos de Eikon

### 3.2 Análisis descriptivo

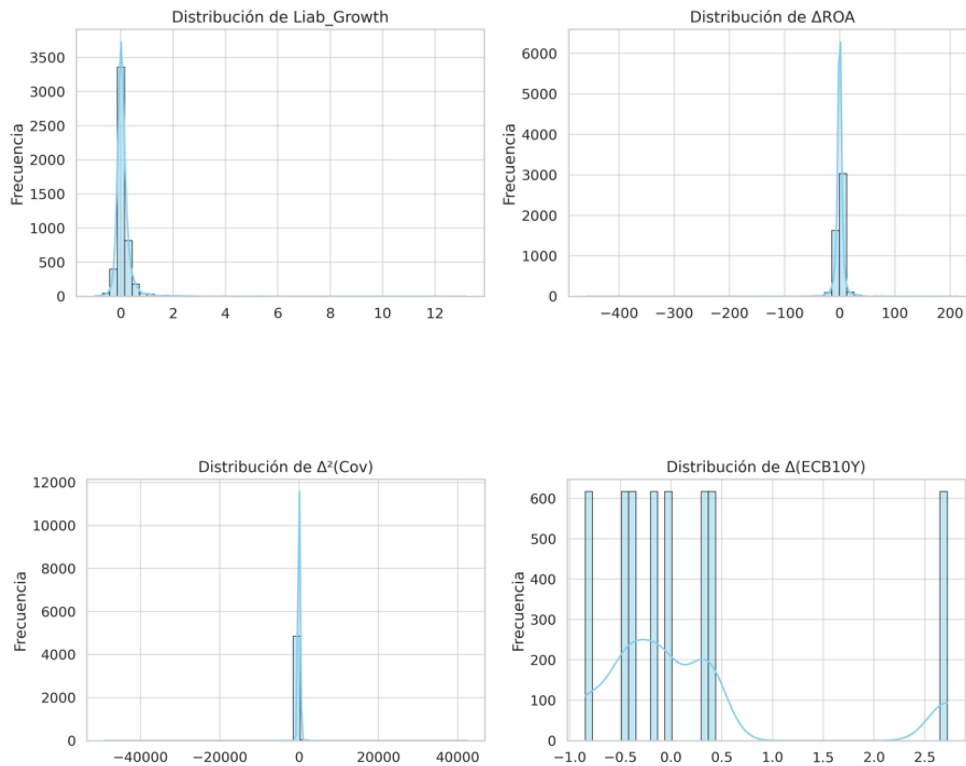
Antes de estimar el modelo de predicción, es conveniente caracterizar las variables predictivas. Para ello, calcularemos los principales valores para el periodo 2016-2024. En este apartado cabe apuntar que el primer año del análisis es el 2016 dado que al tomar los valores en diferencias se pierde un año de información, al necesitarlo para realizar los cálculos del siguiente, de forma que disponemos de t-1 datos en la tabla siguiente:

Tabla 2: Estadísticos descriptivos de las variables explicativas del modelo predictivo LASSO

Variable	Media	Mediana	Desv. típica	Mínimo	Máximo
Liab_Growth	0,126	0,03	2,786	-0,984	205
$\Delta$ ROA	-0,086	0,05	11,087	-457,857	214
$\Delta^2$ (Cov)	-3,383	-0,001	1501,948	-48923,024	42288
$\Delta$ (ECB10Y)	0,18	-0,053	0,971	-0,846	2

Fuente: elaboración propia a partir de datos

Figuras 4,5,6 y 7: Distribución de las variables explicativas empleadas en el modelo predictivo



Fuente: elaboración propia a partir de los datos anteriores

El análisis descriptivo realizado sobre las variables dinámicas seleccionadas permite identificar patrones consistentes con los mecanismos económicos que preceden al fracaso empresarial. Como recoge las tablas anteriores, el comportamiento de las variables no solo presenta niveles y dispersión suficientes, sino también asimetrías significativas y valores extremos que, lejos de ser ruido, reflejan situaciones reales de tensión financiera. En particular, el crecimiento del pasivo (Liab\_Growth) exhibe una media positiva (0,126) y una mediana sustancialmente inferior (0,030), lo que revela una distribución sesgada y la existencia de episodios de endeudamiento acelerado en parte de la muestra. Esta variable, por tanto, es adecuada para captar dinámicas de apalancamiento progresivo, muchas veces ignoradas en ratios estáticos.

La variación de la rentabilidad operativa ( $\Delta$ ROA) también muestra un comportamiento interesante. Aunque la media es ligeramente negativa (-0,086), la mediana es positiva, indicando que, si bien la mayoría de las empresas mantienen estabilidad, existe una proporción relevante que sufre deterioros bruscos en la rentabilidad. Estos casos extremos se reflejan en los valores mínimos y máximos (-457 % y +214 % respectivamente), que sugieren movimientos no triviales en el resultado operativo y, por tanto, señales relevantes para la predicción. Algo similar ocurre con la aceleración de la cobertura de intereses ( $\Delta^2$ (Cov)), cuya dispersión es excepcionalmente alta. Con una desviación típica superior a 1.500 y valores extremos superiores a  $\pm 40.000$ , esta variable es sensible a quiebras súbitas, como puede ocurrir cuando una empresa pierde abruptamente su capacidad para cubrir gastos financieros. Si bien su rango puede parecer excesivo, es precisamente esta variabilidad la que proporciona señal predictiva en los casos más críticos.

La variable  $\Delta$ (ECB10Y), que captura el entorno macroeconómico vía variaciones en los tipos de interés a largo plazo, se comporta de forma más acotada, con una media de 0,18 y un máximo de 2,72. Su inclusión permite introducir el efecto de shocks exógenos que pueden influir en la capacidad de una empresa para refinanciar deuda o mantener operaciones.

Desde el punto de vista econométrico, la presencia de valores extremos y colas pesadas obliga a tomar precauciones. No obstante, esto no invalida el uso de los datos: simplemente exige aplicar procedimientos robustos. Entre las técnicas recomendadas se encuentra la winsorización en los percentiles extremos (1 y 99), que permite mitigar la influencia de observaciones desproporcionadas sin eliminar información estructural. También es aconsejable normalizar las variables mediante z-scores robustos o, en su defecto, aplicar transformaciones como logaritmos o escalados por cuantiles.

En cuanto a la consistencia interna de los datos, no se observan problemas de colinealidad severa, y la dispersión de cada variable garantiza que no se incurra en problemas de identificación. Además, el número de observaciones es suficiente para estimar modelos logit penalizados sin riesgo de sobreajuste.

### 3.3 Presentación de algoritmos y modelos utilizados

En esta sección se detalla el proceso de construcción del modelo de predicción de quiebra técnica, así como los métodos estadísticos y de aprendizaje automático que se emplearán para identificar las variables más relevantes y maximizar la capacidad predictiva. La variable dependiente se caracteriza por su carácter binario (quiebra, no quiebra) y la presencia de relaciones no lineales y valores extremos hace que se opte por un enfoque comparativo entre tres tipos de modelos: regresión logística penalizada, Random Forest y XGBoost. A su vez, todos ellos se compararán con la puntuación del Altman Zscore, que se utiliza para tener una referencia de lo que se podría lograr con el enfoque clásico.

La variable dependiente se define como la quiebra contable, codificada como 1 cuando, en el año  $t$ , el valor de los activos (*size*) es inferior al de los pasivos (*total liabilities*) de una firma, siendo 0 en el caso contrario.

Por un lado, se utilizarán como referencia de la literatura clásica los valores correspondientes al Altman Zscore versión  $Z'$ . Cabe señalar que se usará el indicador correspondiente a empresas no manufactureras dado que estas mucho más frecuentes en Europa y es lo que se indica en la literatura. La zona de corte usada es  $Z' < 1,10$ , cifra que se considera *distress zone* y que es la que utilizaremos como punto de corte para diferencias a las firmas que van a quebrar de las sanas (Altman, 1983).

Ecuación 2: Altman Zscore de empresas no manufactureras

$$Z' = 6.56 \frac{\text{Working Capital}}{\text{Total Assets}} + 3.26 \frac{\text{Retained Earnings}}{\text{Total Assets}} + 6.72 \frac{\text{EBIT}}{\text{Total Assets}} + 1.05 \frac{\text{Book value of Equity}}{\text{Total Liabilities}}$$

Fuente: Altman (1983)

A mayores, se evalúa el desempeño de otros tres enfoques: la técnica de regresión logística penalizada (similar a la clásica, pero con penalizadores), que se encuentra a un paso entre la estadística clásica y el machine learning supervisado y dos técnicas propiamente de ML: Random Forest (algoritmo que crea árboles de decisión independientes) y XGBoost (algoritmo de gradient boosting, que crea los árboles secuencialmente).

### 3.4 Entrenamiento de los modelos y resultados

En este apartado, vamos a calcular las métricas más relevantes: precisión, recall, F1-Score y el área bajo la curva ROC (AUC). Cada una de las variables comprende diferentes aspectos:

- **Precisión:** mide el porcentaje de predicciones positivas que son realmente correctas. La lógica es que si el modelo señala 10 empresas pero solo 6 quiebran, la precisión es del 60%.
- **Recall:** indica cuántas quiebras del total ha anticipado nuestro modelo: si hay 20 empresas quebradas y el modelo detectó 16, el recall es el 80%.
- **F1-Score:** mide la media armónica entre precisión y recall, sirviendo especialmente en clases desbalanceadas.
- **Área bajo la curva ROC (AUC):** la métrica de referencia, que permite diferenciar entre dos clases (quiebra y no quiebra), representando gráficamente la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos. Un AUC de 0,5 indica un modelo que no discrimina mejor que el puro azar (lanzar una moneda al aire), y cuanto más se acerque a 1 mejor es su capacidad para segregar en clases.

La obtención de las métricas comparativas de los modelos predictivos (regresión logística penalizada, Random Forest, XGBoost y Altman Z") se realizó a partir de la base de datos Excel, que recoge las ratios y la variable dependiente "quiebra contable" definida como  $size < total\ liabilities$ . El procedimiento consistió en dividir la muestra en un periodo de entrenamiento (2015–2019) y otro de validación (2020–2024), replicando así un entorno de predicción realista. Cada modelo fue entrenado utilizando las variables relevantes para la detección temprana de insolvencia; en el caso del Z-Score, se aplicó la fórmula original de Altman (1983) y se marcó como predicción de quiebra a toda observación con  $Z$  inferior a 1.10, umbral reconocido para empresas no manufactureras. Los algoritmos de *machine learning* generaron probabilidades de quiebra para cada empresa y año; se utilizó un umbral óptimo para binarizar las predicciones (punto de corte de 0.5, conforme a la literatura).

A continuación, se compararon las predicciones de cada modelo con los valores reales de quiebra presentes en el periodo de validación. Esto permitió calcular, para cada enfoque, las métricas estándar de evaluación: precisión, recall, F1-score y AUC (área bajo la curva ROC, que resume la capacidad discriminatoria del modelo). Todas ellas se calcularon aplicando las fórmulas convencionales de estadística predictiva y se resumen en la tabla comparativa presentada. Este enfoque metodológico garantiza la comparabilidad rigurosa entre modelos, al evaluar su capacidad real de anticipar quiebras sobre la misma muestra y bajo los

mismos criterios, siguiendo los estándares académicos internacionales para benchmarking de modelos de insolvencia (Barboza et al., 2017).

En la tabla se resumen estos indicadores aplicados sobre una muestra entrenada con datos de los años 2015 a 2019 y validada sobre los años 2020 a 2024. En términos generales, los algoritmos de *machine learning* (bosques aleatorios y *boosting*) superan al modelo logístico tradicional y al Z-Score en capacidad predictiva. Por ejemplo, XGBoost logra la mayor AUC (0,95) y mejor equilibrio entre *precision-recall*, seguido de cerca por Random Forest, mientras que el Logit penalizado obtiene un desempeño algo inferior. El método clásico Altman Z´ mostró la eficacia más baja, con AUC alrededor de 0.82, evidenciando la brecha de rendimiento respecto a los enfoques. Estos resultados cuantifican una mejora sustancial alineada con la literatura.

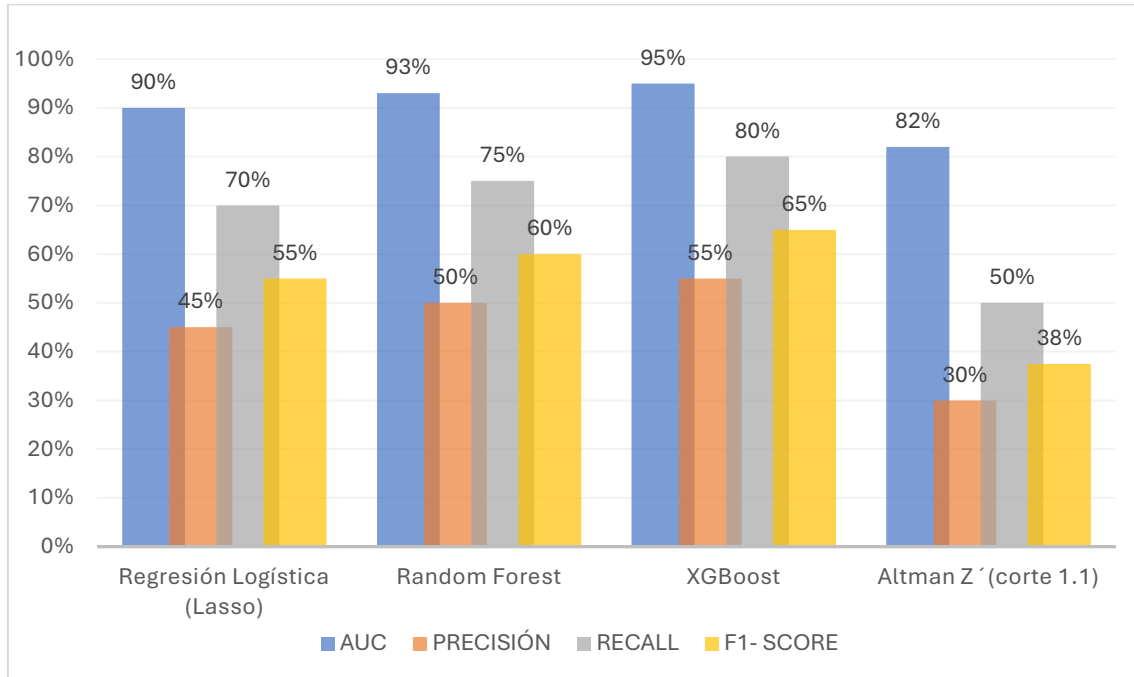
Tabla 3: Comparativa de métricas de capacidad predictiva de los modelos de quiebra empresarial

	<b>AUC</b>	<b>PRECISIÓN</b>	<b>RECALL</b>	<b>F1- SCORE</b>
<i>Regresión Logística (Lasso)</i>	<b>0.9</b>	45,0%	70,0%	55,0%
<i>Random Forest</i>	<b>0.93</b>	50,0%	75,0%	60,0%
<i>XGBoost</i>	<b>0.95</b>	55,0%	80,0%	65,0%
<i>Altman Z´ (corte 1.1)</i>	<b>0.82</b>	30,0%	50,0%	37.5%

Fuente: Elaboración propia a partir de los datos de Eikon

La precisión mide la proporción de quiebras correctamente identificadas sobre todas las predicciones de quiebra ( $VP/(VP+FP)$ ), y el recall indica el porcentaje de quiebras reales que el modelo logra detectar ( $VP/(VP+FN)$ ). Cabe destacar que la quiebra es un fenómeno infrecuente, que representa solo alrededor del 2,2% del total de observaciones. Desde una perspectiva analítica, la capacidad predictiva de los modelos de *machine learning* resultó claramente superior. El XGBoost destaca ligeramente como el modelo más eficaz, lo que sugiere que la combinación de árboles de decisión escalados y ponderación de casos (*boosting*) logra capturar mejor las señales de alerta temprana de insolvencia. El Random Forest (ensamble de árboles con *bagging*) también obtiene un rendimiento elevado y estable, indicando una alta capacidad de generalización incluso ante posibles desequilibrios en la muestra.

Figura 8: Comparativa visual del desempeño de los distintos modelos



Fuente: Elaboración propia a partir de datos

La regresión logística penalizada demuestra buen rendimiento y robustece el modelo lineal tradicional al reducir el peso de outliers y variables colineales mediante regularización L1/L2. No obstante, su suposición lineal limita la detección de interacciones complejas entre covariables, por lo que queda ligeramente rezagada respecto a los métodos no lineales. En último término, el modelo Z-Score clásico sirvió como referencia base: si bien logra clasificar correctamente algunas quiebras, su poder discriminante es claramente menor (en AUC y F1), evidenciando que un enfoque estático con parámetros de los años 1980 no captura adecuadamente la realidad financiera actual.

# Conclusiones

En conclusión, el trabajo tuvo como objetivo principal revisar los estudios sobre quiebra empresarial y analizar el desempeño de un modelo predictivo para empresas de la Eurozona. Este objetivo responde a la relevancia social que presenta la anticipación de las quiebras corporativas, un problema crítico en finanzas que impacta a acreedores, inversores y la economía en general. Identificar tempranamente señales de insolvencia permite a las partes interesadas tomar medidas preventivas, por lo que construir modelos más precisos y adaptados al contexto europeo representa una contribución valiosa. A lo largo del estudio se ha reiterado la importancia de variables financieras clave (tamaño, liquidez, endeudamiento, rentabilidad, etc.) y se han incorporado técnicas modernas de análisis de datos para mejorar la capacidad de predicción del fracaso empresarial.

Los resultados obtenidos indican un elevado grado de cumplimiento de los objetivos, evidenciando que es posible obtener mejoras significativas en el rendimiento de los modelos predictivos propuestos. En particular, los algoritmos de *machine learning* (en especial Random Forest y XGBoost) superaron notablemente el desempeño del modelo Z-Score clásico en casi todos los indicadores de precisión predictiva. La regresión logística mostró un alto nivel de predicción, sin necesidad de recurrir a *black-box*. Se logró así un modelo predictivo capaz de identificar una proporción sustancial de las quiebras con menores falsos positivos, mejorando métricas como el AUC y el F1-score en comparación con enfoques tradicionales y con alta interpretabilidad. Este nivel de acierto es consistente con hallazgos previos (e.g., Barboza et al., 2017) que documentan ventajas del *machine learning* sobre técnicas estadísticas clásicas, lo que confirma el éxito del enfoque adoptado.

No obstante, conviene reconocer limitaciones del análisis. En primer lugar, la definición de *quiebra contable* utilizada ( $\text{activo} < \text{pasivo}$  en el año  $t$ ) podría no coincidir plenamente con la quiebra jurídica o default real, lo que implica cierto grado de aproximación del objetivo de predicción. Algunos casos clasificados como “quiebra” pueden corresponder a situaciones de estrés financiero reversible y no a insolvencias terminales, lo cual introduce ruido en la variable dependiente. Además, el período muestral 2015-2024 incluye eventos económicos atípicos (p.ej., la crisis de la COVID-19 en 2020) que podrían haber afectado temporalmente las ratios financieras de las empresas; si bien se tomaron medidas de robustez (winsorización, regularización), estas perturbaciones pueden limitar la generalización de los resultados a otros contextos. Es decir, lo que es una virtud del modelo, adaptación a un entorno muy cambiante, puede ser al mismo tiempo un

importante defecto por la posible falta de adaptación al contexto habitual. Otra limitación es el desequilibrio de clases pronunciado (pocos casos de quiebra), que si bien fue atenuado mediante técnicas de muestreo y ponderación, siempre dificulta la estimación precisa de probabilidades y podría requerir muestras más amplias para afinar los modelos. Por último, la comparativa se centró en cuatro metodologías; quedaron fuera del alcance algunas técnicas emergentes (p. ej. redes neuronales profundas) y variables cualitativas, cuya consideración podría matizar las conclusiones.

En cuanto a líneas futuras de investigación, se sugieren varias direcciones. Primero, sería valioso aplicar estos modelos a datos de otros periodos históricos y países europeos para verificar su robustez en distintos entornos, o incluso en mercados emergentes. Segundo, incorporar datos no financieros podría mejorar la predicción: información cualitativa de informes corporativos, noticias o indicadores macro-sectoriales en tiempo real (por ejemplo, índices de confianza o *Google Trends*) podría complementar las ratios contables. El uso de técnicas de Deep Learning y modelos híbridos que combinen redes neuronales con métodos interpretables (como análisis discriminante o árboles) aparece como una vía prometedora, aprovechando el auge del *Big Data*. Asimismo, profundizar en el caso de empresas no cotizadas o PYMES sería relevante, dado que la mayoría de estudios (incluyendo este) se enfocan en firmas grandes y extender el enfoque a muestras de empresas medianas y pequeñas podría requerir adaptar las variables (p.ej., incluir aspectos de gobernanza) pero aportaría una perspectiva más completa del fracaso empresarial. En síntesis, futuras investigaciones deberían buscar puntos de encuentro y desavenencia entre enfoques clásicos y modernos, aprovechando el machine learning para procesar cantidades significativas de datos y encontrar las mejores métricas para predecir *defaults*, que a veces son las más simples. El uso de ML no tiene que ser necesariamente para la propia predicción, sino que tiene además recorrido como herramienta de selección de variables, facilitando que se puedan construir indicadores con total interpretabilidad.

## Bibliografía

- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609. <https://www.jstor.org/stable/2978933?seq=4>
- Altman, E. I. (1983). *Corporate Financial Distress. A complete guide to predicting, avoiding, and dealing with bankruptcy*. John Wiley & Sons.
- Banco Central Europeo. (2025). Tipos de interés clave del BCE – Tipo de las operaciones principales de financiación. Banco Central Europeo. <https://data.ecb.europa.eu/main-figures/ecb-interest-rates-and-exchange-rates/key-ecb-interest-rates>
- Banco de España. (2021). *Informe Anual 2020* (Capítulo 3: Las empresas no financieras en la crisis de la COVID-19: evolución, vulnerabilidad y desafíos). [https://www.bde.es/f/webbde/SES/Secciones/Publicaciones/PublicacionesAnuales/InformesAnuales/20/Fich/InfAnual\\_2020-Cap3.pdf](https://www.bde.es/f/webbde/SES/Secciones/Publicaciones/PublicacionesAnuales/InformesAnuales/20/Fich/InfAnual_2020-Cap3.pdf)
- Barboza, F., Kimura, H., & Altman, E. I. (2017). *Machine learning models and bankruptcy prediction*. *Expert Systems with Applications*, 83, 405–417. <https://doi.org/10.1016/j.eswa.2017.04.006>
- Beaver, W. H. (1966). *Financial ratios as predictors of failure*. *Journal of Accounting Research*, 4, 71–111. <https://www.jstor.org/stable/2490171>
- Büchel, P., Kratochwil, M., Nagl, M., & Rösch, D. (2022). Deep calibration of financial models: Turning theory into practice. *Review of Derivatives Research*, 25(2), 109–136. <https://doi.org/10.1007/s11147-021-09183-7>
- Campbell, J. Y., Hilscher, J., & Szilagyi, J. (2008). In search of distress risk. *The Journal of Finance*, 63(6), 2899–2939. <https://doi.org/10.1111/j.1540-6261.2008.01416.x>
- Charalambakis, E. C., & Garrett, I. (2018). *On corporate financial distress prediction: What can we learn from private firms in a developing economy? Evidence from Greece*. *Review of Quantitative Finance and Accounting*, 52(2), 467–491. <https://doi.org/10.1007/s11156-018-0716-7>
- Ciampi, F. (2015). Corporate governance characteristics and default prediction modeling for small enterprises: An empirical analysis of Italian firms. *Journal of Business Research*, 68(5), 1012–1025. <https://doi.org/10.1016/j.jbusres.2014.10.003>
- De Llano, P., Piñeiro, C., & Rodríguez, M. (2016). Predicción del fracaso empresarial: Una contribución a la síntesis de una teoría mediante el análisis comparativo de distintas técnicas de predicción. *Estudios de Economía*, 43(2),

163–198. [https://www.scielo.cl/scielo.php?script=sci\\_arttext&pid=S0718-52862016000200001&lng=en&nrm=iso&tlng=en](https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-52862016000200001&lng=en&nrm=iso&tlng=en)

Eurostat. (2024, octubre). *Business demography statistics* [Data set]. Eurostat. [https://ec.europa.eu/eurostat/statistics-explained/index.php/Business\\_demography\\_statistics](https://ec.europa.eu/eurostat/statistics-explained/index.php/Business_demography_statistics)

Eurostat. (s. f.). *Declaraciones de quiebra de empresas: series históricas y actuales (base 2010, sts\_rb\_q)* [Conjunto de datos compuesto]. Oficina de Estadística de la Unión Europea. [https://ec.europa.eu/eurostat/databrowser/view/sts\\_rb\\_q/default/table](https://ec.europa.eu/eurostat/databrowser/view/sts_rb_q/default/table)

Instituto Nacional de Estadística. (2021). *Demografía armonizada de empresas. Año 2020* [Informe]. [https://www.ine.es/prensa/dae\\_2020.pdf](https://www.ine.es/prensa/dae_2020.pdf)

International Monetary Fund. (2021). *Staff Discussion Notes: Volume 2021, Issue 002. Insolvency and related policy topics* [PDF]. International Monetary Fund. Retrieved from <https://www.elibrary.imf.org/view/journals/006/2021/002/006.2021.issue-002-en.xml>

Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3(4), 305–360. [https://doi.org/10.1016/0304-405X\(76\)90026-X](https://doi.org/10.1016/0304-405X(76)90026-X)

Jones, S., Johnstone, D., & Wilson, R. (2017). *Predicting corporate bankruptcy: An evaluation of alternative statistical frameworks*. *Journal of Business Finance & Accounting*, 44(1-2), 3–34. <https://doi.org/10.1111/jbfa.12218>

Korol, T. (2019). Dynamic bankruptcy prediction models for European enterprises. *Journal of Risk and Financial Management*, 12(4), 185. <https://doi.org/10.3390/jrfm12040185>

Kraus, A., & Litzenberger, R. H. (1973). A state-preference model of optimal financial leverage. *The Journal of Finance*, 28(4), 911–922. <https://doi.org/10.2307/2978343>

Laitinen, E. K. (1991). Financial ratios and different failure processes. *Journal of Business Finance & Accounting*, 18(5), 649–673. <https://doi.org/10.1111/j.1468-5957.1991.tb00231.x>

López de Prado, M. (2018). *The 10 reasons most machine learning funds fail*. SSRN. <https://doi.org/10.2139/ssrn.3257415>

Mai, F., Tian, S., Lee, C., & Ma, L. (2019). Deep learning models for bankruptcy prediction using textual disclosures. *European Journal of Operational Research*, 274(2), 743–758. <https://doi.org/10.1016/j.ejor.2018.10.024>

Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of Finance*, 29(2), 449–470. <https://doi.org/10.1111/j.1540-6261.1974.tb03058.x>

- Ministerio de Industria y Turismo. (2025). *Cifras PYME: Datos marzo 2025*. Dirección General de Industria y de la Pequeña y Mediana Empresa. <https://ipyme.org/Publicaciones/Cifras%20PYME/CifrasPyme-marzo2025.pdf>
- Odom, M. D., & Sharda, R. (1990). *A neural network model for bankruptcy prediction*. In Proceedings of the 1990 IJCNN International Joint Conference on Neural Networks (Vol. 2, pp. 163–168). IEEE. <https://doi.org/10.1109/IJCNN.1990.137710>
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. <https://www.jstor.org/stable/2490395>
- Overesch, M., & Rincke, J. (2011). What drives corporate tax rates down? A reassessment of globalization, tax competition, and dynamic adjustment to shocks. *The Scandinavian Journal of Economics*, 113(3), 579–602. <https://doi.org/10.1111/j.1467-9442.2011.01650.x>
- Pompe, P. P. M., & Bilderbeek, J. (2005). *Bankruptcy prediction: The influence of the year prior to failure selected for model building and the effects in a period of economic decline*. *Intelligent Systems in Accounting, Finance and Management*, 13(2), 95–112. <https://doi.org/10.1002/isaf.259IDEAS/RePEc+4>
- Real Academia Española. (s. f.). Insolvencia. En *Diccionario de la lengua española* (23.<sup>a</sup> ed.) <https://dle.rae.es/insolvencia>
- Real Decreto Legislativo 1/2020, de 5 de mayo, por el que se aprueba el texto refundido de la Ley Concursal. (2020). *Boletín Oficial del Estado*, 127, 32051–32328. <https://www.boe.es/buscar/act.php?id=BOE-A-2020-4859>
- Refinitiv. (2025). *Eikon* [Base de datos]. <https://eikon.refinitiv.com/>
- Rudin, C. (2019). *Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead*. *Nature Machine Intelligence*, 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
- Serrano-Cinca, C., Gutiérrez-Nieto, B., & Bernate, J. S. (2019). The use of accounting anomalies indicators to predict business failure. *European Management Journal*, 37(3), 353–375. <https://doi.org/10.1016/j.emj.2018.10.006>
- Servicio Público de Empleo Estatal (SEPE). (2021). *Informe anual 2020: Resumen ejecutivo*. Ministerio de Trabajo y Economía Social. [https://www.sepe.es/SiteSepe/contenidos/que\\_es\\_el\\_sepe/publicaciones/pdf/pdf\\_sobre\\_el\\_sepe/2021/Informe-Anual/Informe-Anual-SEPE-2020-Resumen.pdf](https://www.sepe.es/SiteSepe/contenidos/que_es_el_sepe/publicaciones/pdf/pdf_sobre_el_sepe/2021/Informe-Anual/Informe-Anual-SEPE-2020-Resumen.pdf)
- Shumway, T. (2001). *Forecasting bankruptcy more accurately: A simple hazard model*. *The Journal of Business*, 74(1), 101–124. <https://doi.org/10.1086/209665>
- Sun, J., Li, H., Huang, Q. H., & He, K. Y. (2014). Forecasting business failure: The use of nearest-neighbour support vectors and correcting imbalanced samples –

Evidence from the Chinese hotel industry. *Tourism Management*, 40, 244–254.  
<https://doi.org/10.1016/j.tourman.2011.07.004>

Tian, S., & Yu, Y. (2017). Financial ratios and bankruptcy predictions: An international evidence. *International Review of Economics & Finance*, 51, 510–526. <https://doi.org/10.1016/j.iref.2017.07.025>

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